

UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA
COMPUTAÇÃO

Jovelino Falqueto

Inspiração biológica em IA

Tese submetida à Universidade Federal de Santa Catarina como parte dos requisitos para a obtenção do grau de Doutor em Ciência da Computação.

Prof. Jorge Muniz Barreto, Dr. - Orientador

Florianópolis, Março de 2002

INSPIRAÇÃO BIOLÓGICA EM IA



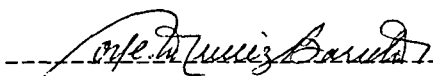
Jovelino Falqueto, M. Sc.

Esta Tese foi julgada adequada para a obtenção do título de Doutor em Ciência da Computação, área de concentração Sistemas de Conhecimento, e aprovada em sua forma final pelo Programa de Pós-graduação em Ciência da Computação da Universidade Federal de Santa Catarina.

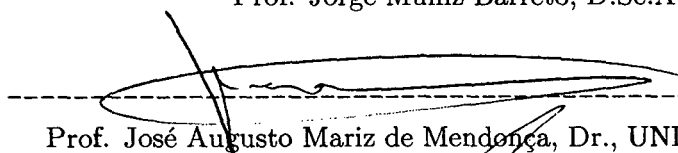


Prof. Fernando A. O. Gauthier, Dr.
Coordenador do Programa

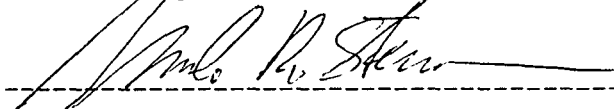
Banca Examinadora:



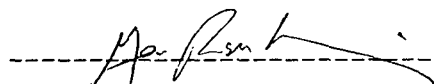
Prof. Jorge Muniz Barreto, D.Sc.A, INE-UFSC, Orientador



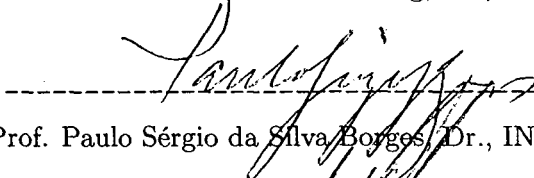
Prof. José Augusto Mariz de Mendonça, Dr., UNITAU-FACNS-JAMMER



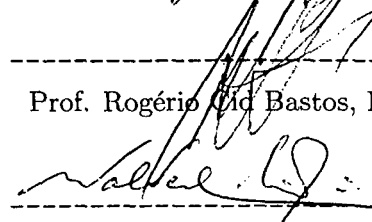
Prof. Marcelo Ricardo Stemmer, Dr., DAS-UFSC



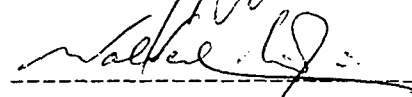
Prof. Mauro Roisenberg, Dr., INE-UFSC



Prof. Paulo Sérgio da Silva Borges, Dr., INE-UFSC



Prof. Rogério Cid Bastos, Dr., INE-UFSC



Prof. Walter Celso de Lima, Dr., UDESC

Florianópolis, 6 de março de 2002.

Ofereço este trabalho
ao meu pai (in memoriam) e à minha mãe;
à Yuta, Letícia, Daniel e Aline.

Agradecimentos

- Ao Deus de minha crença atribuo a causa inicial do Universo e seu fim último, sua arquitetura e criação e é a quem, em primeiro lugar, agradeço;
- Ao meu orientador, Prof. Dr. Jorge Muniz Barreto, pelo acompanhamento sábio, abnegado e amigo com que me atendeu durante todo o trabalho;
- Aos professores Dr. Marcelo Ricardo Stemmer, Dr. Mauro Roisenberg, Dr. Rogério Cid Bastos, Dr. Paulo Sergio da Silva Borges e Dr. Walter Celso de Lima pelas valiosas contribuições;
- Ao Prof. Dr. José Augusto Mariz de Mendonça pela participação;
- Ao Departamento de Informática e Estatística, que, através de seus integrantes, de sua chefia, secretaria e órgãos colegiados, oportunizou este empreendimento;
- Ao Programa de Pós-Graduação em Ciência da Computação, por ter acolhido o projeto desta pesquisa.

Artigos Publicados

As idéias fundamentais deste trabalho foram expostas em eventos científicos internacionais significativos da área de IA, com a finalidade de levar a público os pontos basilares e submeter as idéias referidas na tese ao crivo de revisores externos. Como resultado, o primeiro, terceiro e quarto artigos abaixo foram publicados, o que parece apontar para a significância dos temas tratados. O segundo artigo, em área correlata, também consta da lista, tendo se originado de trabalhos em disciplina cursada no programa de pós-graduação.

1. Artigo: "Amplification of perspectives in the use of Evolutionary Computation";
Evento: IEEE International Symposium; on Bio-Informatics and Biomedical Engineering;
Dados: Arlington, EUA, VA; 8-10 nov. 2000; p. 150-157;
Autores: J. Falqueto; J. M. Barreto; P. S. S. Borges.

2. Artigo: "Uso de agentes para apoio à mediação de diálogos entre estudantes via Internet";
Evento: V Congreso Iberoamericano de Informatica Educativa";
Dados: Vinha del Mar, Chile, 4-6 dez. 2000
<http://www.c5.cl/ieinvestiga/actas/ribie2000/>, ou em CD
Autores: L. J. Komosinski; C. D. F. de Lacerda; J. Falqueto.

3. Artigo: "The measurement of Artificial Intelligence: An IQ for machines?";
Evento: IASTED - International Conference on Modelling, Identification and Control (MIC 2001);
Dados: Innsbruck, Austria; 19-22 fev., 2001; p. 409-413;
Acta Press, Calgary, Zurich; ISBN 0-88986-316-4; ISSN 1025-8973;
Autores: J. Falqueto; W. C. Lima; P. S. S. Borges; J. M. Barreto.

4. Artigo: "O desenvolvimento de uma métrica para sistemas de IA - Considerações";
Evento: II Congreso Latinoamericano de Ingeniería Biomédica;
Dados: Havana, Cuba; 23-25 mai. 2001;
Habana, 2[CD-ROM], Coral, SCB. ISBN 959-7132-57-5, <http://www.hab2001.sld.cu>;
Autores: J. Falqueto; W. C. Lima; P. S. S. Borges; J. M. Barreto.

Conteúdo

Conteúdo	vi
Lista de Figuras	ix
Lista de Tabelas	x
Resumo	xii
Abstract	xiii
1 TÓPICOS INTRODUTÓRIOS	1
1.1 MOTIVAÇÃO	1
1.2 OBJETIVOS	2
1.3 ESTRUTURA DO TRABALHO	3
2 REFLEXÕES SOBRE IA	6
2.1 TÓPICOS HISTÓRICOS E FILOSÓFICOS SOBRE IA	6
2.1.1 Introdução	6
2.1.2 Uma Conquista: A criação da Máquina Computador - Eventos principais	6
2.1.3 Um sonho: a recriação da “máquina homem”	9
2.2 O QUE É A INTELIGÊNCIA	18
2.2.1 Aspectos “Físicos” da Inteligência	18
2.2.2 Aspectos “psicológicos” da Inteligência	20
2.3 A BUSCA DA IA	21
2.3.1 Introdução	21
2.3.2 Marcos históricos na IA	23
2.3.3 Inteligência Artificial Conexionista - IAC - e Inteligência Artificial Simbólica - IAS	23
2.4 ESTUDO DE UMA METODOLOGIA PARA MENSURAÇÃO DA IA: UM QI PARA MÁQUINAS?	30
2.4.1 Ponderações iniciais	30
2.4.2 Alguns enfoques considerados na medição da Inteligência	33

2.4.3	“História” do QI ‘humano’	35
2.4.4	Considerações algébricas	37
2.4.5	Propostas de métricas	39
3	EVOLUÇÃO SOB OS PONTOS DE VISTA DE DARWIN E DE PRIGOGINE	44
3.1	PRINCIPAIS CORRENTES DE EXPLICAÇÃO DA NATUREZA	44
3.1.1	Outras possibilidades de explicação da Natureza	45
3.2	O NEODARWINISMO	51
3.2.1	“Máquinas” de Darwin, Lamarck e de Vries	51
3.2.2	Mitose	53
3.2.3	Meiose	55
3.3	A CONCEPÇÃO DE PRIGOGINE	59
3.3.1	Introdução	59
3.3.2	Uma modelagem analítica da evolução	59
3.4	A EVOLUÇÃO E AS LEIS DA TERMODINÂMICA	68
3.4.1	A três leis da termodinâmica	68
3.4.2	Entropia	70
3.4.3	Processos reversíveis e irreversíveis	72
3.4.4	O tempo e a entropia	73
3.5	FATOS DA NATUREZA ILUSTRATIVOS DAS “MÁQUINAS” DE DARWIN E PRIGOGINE	74
3.5.1	Introdução	74
3.5.2	Exemplos biológicos	74
3.5.3	Exemplos químicos	77
3.5.4	Exemplos sociológicos e psicológicos	78
3.6	CONCLUSÃO	78
4	COMPUTAÇÃO EVOLUCIONÁRIA	79
4.1	INTRODUÇÃO	79
4.1.1	Outras técnicas “naturais”, mas não evolucionárias	82
4.2	ESTRUTURA GERAL DOS PARADIGMAS DE COMPUTAÇÃO EVOLUCIONÁRIA	84
4.2.1	Definições e notações	85
4.2.2	Algoritmo evolucionário genérico	86
4.3	ESTRATÉGIAS EVOLUCIONÁRIAS	87
4.4	PROGRAMAÇÃO EVOLUCIONÁRIA	88
4.5	ALGORITMOS GENÉTICOS	89
4.5.1	Algoritmo Genético Canônico	90
4.6	PROGRAMAÇÃO GENÉTICA	97
4.7	SISTEMAS CLASSIFICADORES	98
4.8	COMPARATIVO ENTRE PARADIGMAS DE COMPUTAÇÃO EVOLUCIONÁRIA	100

4.9	PARADIGMAS DA COMPUTAÇÃO EVOLUCIONÁRIA E A INSPIRAÇÃO NA NATUREZA	102
5	EM BUSCA DE AG MAIS BIOLOGICAMENTE PLAUSÍVEL	108
5.1	INTRODUÇÃO	108
5.2	APLICAÇÃO DE AG AO PROBLEMA DO QUADRADO MÁGICO: EN-SAIO	109
5.2.1	Conceitos preliminares	109
5.2.2	Algoritmo proposto	110
5.3	APLICAÇÃO DE AG: EVOLUÇÃO DE RNA	116
5.3.1	Os AG e as RNA	116
5.3.2	Evolução da arquitetura de uma RNA usando AG	119
5.3.3	Influência da “herança de conhecimento” na evolução de RNA com AG	126
5.4	PROPOSTA DE MÉTRICA PARA IAE	139
6	CONCLUSÃO	141
6.1	EPÍLOGO	144
6.1.1	Propostas para novas pesquisas	144
6.1.2	Palavras finais	145
7	ANEXO	147
7.1	DADOS MÉDICOS REUMÁTICOS ORIGINAIS	147
	Referências Bibliográficas	153

Lista de Figuras

2.1	A vida da terra na escala de um ano.	42
2.2	Uma proposta de classificação da IA.	43
2.3	Evolução dos custos de construção de SE.	43
3.1	Processo evolucionário segundo Lamarck.	53
3.2	Processo evolucionário segundo Darwin.	53
3.3	A mutação no processo evolucionário, segundo de Vries.	54
3.4	Formação das cromátides na divisão meiótica.	55
3.5	Processo de recombinação gênica ou “crossing-over”.	56
3.6	“Máquina neodarwiniana” no processo evolucionário.	57
3.7	O fator tempo no processo evolucionário.	58
3.8	Mudança de comportamento de um sistema Bénard ao atingir um ponto crítico.	60
3.9	Multiplicidade de soluções em função dos parâmetros de controle.	62
3.10	Bifurcações no processo evolutivo.	63
3.11	Variação da energia térmica em ciclo reversível.	71
3.12	Componentes da entropia em sistemas abertos e fechados.	72
4.1	Computação Natural - Áreas de estudo inspiradas na Natureza.	81
4.2	Têmpera simulada: Variação dos valores da função de aptidão.	84
4.3	Sistemas evolucionários: elementos principais.	85
4.4	Passos gerais do Algoritmo Genético Canônico.	91
4.5	Fluxograma de um Algoritmo de PG, conforme Koza.	98
4.6	Os dois modos de trabalho de um Sistema Classificador.	99
4.7	A Natureza como fonte de solução dos problemas humanos.	106
5.1	Fluxograma de um AG para solução do Quadrado Mágico.	115
5.2	Fluxograma genérico para emprego de AG na evolução da arquitetura de RNA.	122
5.3	Interface de sistema com emprego de AG na evolução da arquitetura de RNA.	123
6.1	Os fatores <i>inteligência e trabalho</i>	143

Lista de Tabelas

4.1	Método do Gradiente: Valores em R e R^n	83
4.2	Paralelo entre conceitos da Biologia e de Computação Evolucionária.	85
4.3	Comparativo entre Estratégias Evolucionárias, Programação Evolucionária e AG.	101
5.1	Valores fornecidos com taxa de recombinação de 20% e 85%.	116
5.2	Diagnósticos médicos possíveis para os dados obtidos.	119
5.3	Dados parametrizados com 40 casos médicos de pacientes reumáticos	121
5.4	Influência da Camada Intermediária e do número de épocas.	127
5.5	Influência da Camada Intermediária e do número de épocas (caso “descendente”).	129
5.6	Evolução das RNA ao longo de 6 gerações e 150 épocas, <i>sem herança</i>	131
5.7	Número de saídas corretas na fase de treinamento das redes, <i>sem herança</i>	132
5.8	Percentuais de acerto de cada rede, ‘em tempo de verificação’, <i>sem herança</i>	133
5.9	Amostra da saída da rede, em período de verificação, com 65% de acertos.	134
5.10	Evolução das RNA ao longo de 6 gerações e 150 épocas, <i>com herança</i>	136
5.11	Número de saídas corretas na fase de treinamento das redes, <i>com herança</i>	137
5.12	Percentuais de acerto de cada rede, ‘em tempo de verificação’, <i>com herança</i>	139
7.1	Tabulação dos dados obtidos em clínica médica.	148
7.2	Tabulação dos dados obtidos em clínica médica - (<i>Continuação da Tabela 7.1</i>).	149
7.3	Significado das abreviações utilizadas na Tabela 7.1.	150
7.4	Descrição dos diagnósticos da Tabela 7.1.	151
7.5	Descrição dos diagnósticos da Tabela 7.1 - (<i>Continuação da Tabela 7.4</i>).	152

Lista de Abreviações

ADN	Ácido desoxirribonucléico
AG	Algoritmo Genético
A G C T	Bases nitrogenadas: Adenina, Guanina, Citosina, Timina
CC	Ciência da Computação
CE	Computação Evolucionária
DOS	Disk Operating System
EE	Estratégia Evolucionária
IA	Inteligência Artificial
IAC	Inteligência Artificial Conexionista
IAD	Inteligência Artificial Distribuída
IAE	Inteligência Artificial Evolucionária
IAH	Inteligência Artificial Híbrida
IAS	Inteligência Artificial Simbólica
MB	Mega Byte: $2^{10} = 1024$ “bytes”
PDP	“Parallel Distributed Processing”: Processamento Paralelo e Distribuído
PE	Programação Evolucionária
QE	Quociente Emocional
PG	Programação Genética
QI	Quociente de Inteligência
QS	Quociente espiritual (SQ: “Spiritual Quotient”)
RAM	“Random Access Memory”: Memória de acesso aleatório
RN	Redes Neurais
RNA	Redes Neurais Artificiais
SC	Sistemas Classificadores
SE	Sistema Especialista
UCP	Unidade Central de Processamento
www	“World Wide Web”: Rede Mundial de Computadores
XOR	Porta ou-exclusivo (“eXclusive Or”)

Resumo

O objetivo principal deste trabalho é explorar as possibilidades de estender as atuais fronteiras dos campos de aplicação dos paradigmas de IA, através de uma cópia mais fiel de inspirações biológicas. Dessa forma, o objetivo global foi dividido em quatro idéias principais: i) Verificar as possíveis soluções oferecidas pela Natureza, ainda não exploradas pela IA, especialmente pelos paradigmas de Computação Evolucionária; ii) Desenvolver um modelo para implementar no AG uma daquelas soluções; iii) Testar este modelo em uma situação prática; iv) Estudar a proposição de uma possível metodologia para mensurar as variações de inteligência entre sistemas de IA Simbólicos, Conexionistas, Evolucionários ou outros. Como consequência de uma avaliação geral das metodologias de IA, apontar a necessidade de definições mais precisas, juntamente com a utilidade de uma métrica para sistemas de IA. É mostrada a conveniência de dotar os sistemas de IA com a visão dada pelo Prêmio Nobel de Química, Ilya Prigogine, que indicou formas para analisar os fenômenos evolucionários com a ajuda das leis físicas, como as da termodinâmica. São feitos testes para verificar os resultados práticos da adoção de “métodos mais naturais” na construção de sistemas de IA Evolucionária no tratamento de problema com espaço de soluções finito, vulgarmente conhecido por “quadrado mágico”. Foi executada uma segunda implementação para verificar estas idéias, usando AG para evoluir redes neurais com dados extraídos de sintomas de doenças reumáticas. Neste caso, os resultados obtidos mostram que algoritmos evolutivos que sigam mais cuidadosamente os fenômenos da Natureza podem ter sua eficiência melhorada em relação aos que simplesmente adotam os operadores comuns.

Palavras-chave: Inteligência Computacional, Computação Evolucionária, Algoritmos Genéticos, Inspiração Biológica, Inteligência Artificial, Métricas de IA.

Abstract

Use of Biological Inspiration towards a better Artificial Intelligence

This work explores the possibilities to extend the current borders of AI paradigms, along with their application fields, by means of pursuing a more accurate use of the hints supplied by Nature. The dissertation implements its global objective by splitting it into four main streams: (i) Attaining feasible solutions offered by Nature to complex problems, not yet fully taken advantage of by traditional AI methods, especially those pertaining to the area of evolutionary computation; (ii) Building a model to enhance the genetic algorithm technique with inspiration in one of the previously mentioned solutions; (iii) Run tests of that model applied to a practical situation; (iv) Study and discuss a preliminary proposal of a methodology aiming at the task of measuring the performance, in regard to their solving power, of different AI paradigms, namely Symbolic, Connectionist and Evolutionary. Following a general survey of the usual AI methods, appears the need of establishing a more exact definition of what can be understood by machine intelligence, and how to rank the machines' ability of solving problems, relative to some metrics. Additionally, the feasibility, and even desirability of promoting the enrichment of AI systems with the approach introduced by the Nobel laureate Ilya Prigogine, which indicated means of analyzing evolutionary phenomena with the help of physical laws, such as thermodynamics, is particularly supported in this work. The practical advantages of adopting, in a more realistic manner, "natural clues" provided by Nature when designing evolutionary AI systems are tested. Firstly, with the help of a simple puzzle known as the "magic square", whose solutions belong to a discrete finite space, and secondly, by implementing a method to evolve artificial neural networks employing genetic algorithms. The latter is fed with data regarding rheumatic diseases symptoms, and the yielded results supply some evidence that the algorithms used in AI systems can augment their performance when they are more accurately inspired in natural schema.

Keywords: Computational Intelligence, Evolutionary Computation, Genetic Algorithm, Biological Inspiration, Artificial Intelligence, AI metrics.

Capítulo 1

TÓPICOS INTRODUTÓRIOS

“Ninguém comete erro maior do que aquele que não faz nada porque só pode fazer um pouco” - Edmund Burke

1.1 MOTIVAÇÃO

O objetivo de se criar sistemas que substituam o homem em seus afazeres é inerente à sua natureza e, como se verá mais detalhadamente nos Capítulos 2 e 3, vem de tempos imemoriais. O advento da informática deu ao ser humano mais esperança na consecução desta meta. Já nos seus primórdios, algumas possibilidades de imitação da inteligência pelos sistemas computacionais foram estudadas [TUR 50]. Embora com altos e baixos ao longo da curta história da Ciência da Computação, as pesquisas nesta área sempre estiveram ativas e nos últimos anos do século XX praticamente “contaminaram” quase todos os campos desta ciência, a ponto de ser quase um consenso o fato de que novos produtos de informática devem ter embutidos, pelo menos sob algum aspecto, os avanços trazidos por esta pesquisa.

Ao mesmo tempo e como consequência deste esforço, foi sendo construído um corpo de conhecimentos que, embora ainda não esteja totalmente formalizado e sedimentado, pode ser englobado nas áreas conhecidas como Inteligência Artificial Simbólica, Inteligência Artificial Conexionista e Computação Evolucionária, discutidas nos Capítulos 2, 3 e esquematizadas na Figura 2.2 e na 4.1.

O problema é tão complexo, constituído de tantas facetas, com repercussões tão profundas em praticamente todas as atividades exercidas pelo homem - já que supostamente a inteligência está presente em cada um de seus atos - que poucas áreas da ciência (se é há que alguma), não têm interface com ele. Como consequência, as metodologias e os sistemas que procuram mimetizar os processos inteligentes são pesquisados com afimco e os existentes usados com sofreguidão, o que ainda mais motiva a perseguição do objetivo inicial de alargamento das fronteiras do que se sabe sobre a inteligência, de formas a se usar estes conhecimentos para a construção de melhores metodologias e sistemas.

Como dito, os ângulos de ataque ao problema são inúmeros e esta é outra explicação da sua escolha, pois nem sempre é imprescindível um conhecimento inicial

importante para que o estudioso de uma faceta produza um novo avanço científico. Como se verá, sobretudo no Capítulo 3, a área da Computação Evolucionária tem produzido interessantes soluções de problemas pouco tratáveis com as ferramentas tradicionais e se verá que seu método básico é a “cópia da roda”, isto é, aplicar no problema a ser solucionado a mesma sistemática com que a Natureza vem resolvendo um dos maiores desafios já postos: a criação, manutenção e evolução da vida. O modelo evolucionista¹ tem dado aos cientistas de computação importantes idéias para utilização dos mesmos mecanismos envolvidos e se verificará que a aplicação de três deles - seleção, mutação e recombinação - advindos da *teoria “neodarwinista”*, mostra-se muito eficaz para uma série de situações.

Por outro lado, uma indagação natural surge com a constatação de que o uso de mecanismos, que embora biologicamente muito complexos, têm simulação computacional relativamente simples e permitem a solução de problemas intrincados: Não é de se esperar que algum refinamento nestas ferramentas produzam resultados ainda melhores? Esta é outra explicação motivacional da escolha do tema. Esta percepção parece ser aceita pela comunidade acadêmica envolvida [FAL 00].

A relevância do tema abordado pode ser aquilatada pela extensão das conseqüências da criação de novos mecanismos que tornem mais eficientes e abrangentes os paradigmas de otimização existentes. De fato, como grande parte dos trabalhos científicos geralmente se concentram na solução de problemas aplicando metodologias existentes, ou mesmo através de suas combinações ou extensões, observa-se o efeito multiplicador de um desenvolvimento que adicione nova ferramenta às atuais ou lhes indique melhorias. Outro fato que bem demonstra a importância dada pela comunidade científica à pesquisa relacionada com o conhecimento da evolução da vida é o Projeto do Genoma Humano [MAR 96].

O paradigma do Algoritmo Genético se apóia nas inspirações advindas da pesquisa biológica, que está fervilhando de novidades, o que cria um ambiente propício ao retorno à Natureza para verificar o que ela pode nos ensinar com seus bilhões de anos de experiência.

Finalmente, a pesquisa e o ensino de Inteligência Artificial no Centro Tecnológico da Universidade Federal de Santa Catarina, em diversos programas, tem tido um grupo de professores sempre ativamente empenhados. Nos últimos tempos, com a criação de novos cursos de Pós Graduação e a chegada de professores com formação na área, fomentaram ainda mais sua atividade e deram a sustentação necessária para que trabalhos de conteúdo importante sejam desenvolvidos. Estes itens formam o arcabouço motivacional deste trabalho.

1.2 OBJETIVOS

• OBJETIVO GERAL

O objetivo mais amplo que norteia este trabalho é o estudo de metodologias adotadas

¹Os termos ‘evolutivo’, ‘evolucionista’ e ‘evolucionário’ são aqui utilizados com sentido equivalente.

pela Natureza na solução do problema do surgimento e da continuidade da vida na terra, sob a perspectiva evolucionária e em consequência propor alguma aplicação no aperfeiçoamento das ferramentas adotadas pela Computação Evolucionária.

• OBJETIVOS ESPECÍFICOS

1. Estudar os pressupostos filosóficos que embasam a pesquisa em Inteligência Artificial sob o prisma evolucionário;
2. Avaliar os itens estruturais básicos que atualmente compõem as três principais áreas da Inteligência Artificial: Inteligência Artificial Simbólica - IAS, Inteligência Artificial Conexionista - IAC e Inteligência Artificial Evolucionária - IAE (ou Computação Evolucionária - CE)² (Ver Figura 4.1);
3. Fazer um levantamento das principais características dos paradigmas que hoje compõem a CE, com maior ênfase em Algoritmos Genéticos - AG;
4. Relacionar os mecanismos históricos da teoria do darwinismo e do neodarwinismo, bem como de algumas outras doutrinas existentes, para explicar os fenômenos do surgimento, da manutenção e da evolução dos seres vivos;
5. Avaliar os mecanismos adotados pela Natureza possivelmente utilizáveis em IA, ou já implementados de forma simplificada;
6. Mostrar a possibilidade de aproveitar, nos sistemas de IA, o estudos feitos por Ilya Prigogine, indicando meios de análise dos fenômenos evolucionários com o apoio das leis físicas, como as da termodinâmica;
7. Adotar um dos itens citados levantados no objetivo anterior - a assincronia existente entre os períodos das gerações - e implementar um sistema que simule sua aplicação em AG;
8. Aplicar o sistema citado no item anterior em amostras de problemas de AG, analisando os resultados obtidos, vantagens e desvantagens;
9. Propor novos desenvolvimentos para dar seqüência aos trabalhos efetivados nesta tese.
10. Estudo inicial de propostas para métricas de IA.

1.3 ESTRUTURA DO TRABALHO

No Capítulo introdutório se lançam os pressupostos básicos que motivaram o direcionamento do trabalho, os objetivos gerais e específicos que são almejados.

O Capítulo 2 se ocupa com a descrição dos antecedentes filosóficos, históricos e com breve visão panorâmica dos paradigmas simbólico e evolucionista da IA. Mostra-se que os primeiros registros históricos da espécie humana já trazem os sinais das dúvidas transcendentais que a afligem: *Quem é o homem? De onde veio? Para onde vai?*.

²Com relação ao emprego das denominações IAE e CE, ver item 4.1.

Lembra-se a importância desta abordagem pelo fato de as respostas a estas questões agirem como pressupostos à investigação da IA. Relacionando-se ainda com esta idéia, discute-se ligeiramente as possibilidades da Mecânica Clássica, da Relativista e da Quântica, como tentativas de concepção do mundo, pelo “enfoque físico”. Algumas abordagens filosóficas, tais como a teoria *monista* e a *dualista*, são levemente discutidas. Dentre as inúmeras correntes “religiosas”, umas poucas foram citadas.

A mesma indagação feita sobre o homem como um todo, vale para a inteligência e são apresentados as abordagens exploratórias que melhor se adaptam à sua implementação em sistemas, um dos objetivos da IA.

Como consequência da constatação da necessidade de ferramentas que permitam a comparação quantitativa entre os paradigmas de IA, desenvolve-se a proposição de possíveis ensaios metodológicos que resultem em métricas para a quantificação da “inteligência” dos sistemas de IA.

Os principais mecanismos em que se baseia a *teoria evolucionista “neodarwinista”*, bem como de outras teorias explicativas para o surgimento dos seres vivos, são colocadas no Capítulo 3. A importância do enfoque “neodarwinista” se deve à adoção de seu ferramental básico de explicação do surgimento de manutenção da vida e da inteligência. Neste Capítulo também se mostra a abordagem do Prêmio Nobel Ilya Prigogine [PRI 85], que propõe uma formalização analítica para certos parâmetros físicos intervenientes em fenômenos evolutivos, olhando-se os seres vivos como sistemas abertos sujeitos às leis da termodinâmica.

Os paradigmas que atualmente compõem a Computação Evolucionária são estudados no Capítulo 4 e nele se destacam pontos em que estes paradigmas se afastam ou se aproximam da inspiração advinda dos fenômenos biológicos, que foram sua motivação inicial. Ênfase especial é dada ao Algoritmo Genético.

As outras metodologias da CE, nomeadamente, Estratégias Evolucionárias, Programação Evolucionária e Programação Genética são tratadas apenas em relação aos aspectos comparativos.

No quinto Capítulo se adota a sincronia da transmissão de ensinamento ocorrida com os nascimentos dos indivíduos de uma espécie, formando sucessivamente as várias gerações de um Algoritmo Genético, abrangidas em uma simulação, como foco principal a ser trabalhado. Na Natureza, raras são as espécies onde esta sincronização é regra, e, ao contrário, naquelas onde há maior interação entre gerações anteriores e atuais, mais se observa o “sucesso evolutivo” [GAR 94]. Este sucesso é ambivalente no sentido em que seres mais simples na escala filogenética, como a barata, estão perfeitamente adaptados para viver em inúmeros habitats. No intuito de propor metodologia que explore esta propriedade bastante óbvia e natural e no de chamar a atenção de que mais importância deve ser dada à procura de soluções existentes, este trabalho é principalmente pautado nesta parte do texto.

O Capítulo 6 traz conclusões oriundas das metodologias trabalhadas, bem como dos estudos feitos, além de idéias para prosseguimento dos temas em pesquisas futuras. Aponta-se ainda que a inteligência, acoplada ao fator “trabalho”, tem mostrado ser

uma combinação de sucesso na Natureza e deverá também valer para as aplicações de IA.

Os anexos trazem as tabelas dos dados referentes à sintomatologia de pacientes reumáticos utilizada para a aplicação discutida no Capítulo 5.

Capítulo 2

REFLEXÕES SOBRE IA

“Pelo que fizeram, se hão de condenar muitos. Pelo que não fizeram, todos. A omissão é um pecado que se faz não fazendo” (Pe. Antônio Vieira)

2.1 TÓPICOS HISTÓRICOS E FILOSÓFICOS SOBRE IA

2.1.1 Introdução

Neste Capítulo será visto um breve relato dos principais eventos ocorridos na história da computação, sobretudo aqueles aspectos de interesse relevante em Inteligência Artificial - IA.

O homem tem como um de seus objetivos a criação de máquinas que lhe tornem mais fácil a vida, inclusive de máquinas semelhantes a si próprio, o que será objeto do segundo item. Desde tempos imemoriais o ser humano tem procurado responder a três indagações filosóficas básicas: *“Quem somos? De onde viemos? Para onde vamos?”*. Nos dias atuais a resposta a estas indagações tem importância para o projeto de criar máquinas que exibam inteligência, à semelhança da espécie humana. A exposição destes temas ensejará o início da discussão do assunto central deste trabalho: O problema da IA.

2.1.2 Uma Conquista: A criação da Máquina Computador - Eventos principais

É muito popular a passagem bíblica descrevendo a expulsão do Éden, desde quando pesa sobre a cabeça dos homens a sentença: *“Ganharás o pão com o suor do teu rosto”* [BÍB 87]. Também se sabe que cada homem, a começar do primeiro - se é que houve um primeiro - tem na procura da felicidade o objetivo maior de sua vida. Esta busca dá trabalho. Por outro lado, se há que se trabalhar para se perseguir a felicidade, que as tarefas estejam sujeitas, sempre que possível, à *“lei do menor esforço”*. Esta é uma das primeiras das tantas leis *naturais* descobertas e de outras ainda institucionalmente criadas para ajudar ou estorvar a

vida. Obediente a esta lei, o homem se obriga a criar ferramentas, mecanismos, máquinas, tecnologias, que facilitem seu dia a dia, e minimizem a energia dispendida ¹.

Uma das grandes motivações para o emprego dos dedos no trabalho de contagem de animais, de rebanhos, ou de distâncias percorridas pelos nossos ancestrais é aplicação direta da lei em causa, atividades que quase certamente só começaram a ser exercidas há pouco mais de cem mil anos, quando o homem moderno - o *Homo sapiens* - “surgiu” na terra [AMA 94]. Do termo latino “digitus” originaram-se as palavras dedo, dígito, digital e correlatas. Dos dedos se passou à contagem com pedras e novamente o Latim nos legou o termo “calculus”. Como se vê, o cálculo, que na matemática moderna está mais associado a áreas como Cálculo Diferencial, Cálculo Integral, Cálculo Vetorial, etc., tem origens bem “humildes” e antigas. A tarefa de contagem foi desincumbida ainda com outros mecanismos como os pequenos nós em cordas, os quipos dos povos incas, traços na pedra, no barro, no couro, etc. Os povos orientais, desde eras que retrocedem há mais de 5000 anos e ainda nos dias atuais, têm um instrumento bem mais sofisticado que pobres pedras ou nós em cordões, o ábaco, um grande auxiliar de cálculo.

A Wilhelm Schickard (1592 - 1635), matemático e astrônomo alemão, alguns atribuem a criação da primeira calculadora mecânica. Também no início do século XVII o inglês John Napier construiu as tábuas logarítmicas e as famosas réguas de cálculo, preciosos instrumentos de ajuda aos engenheiros, úteis ainda na década de 60 do século XX, quando perderam o posto para as calculadoras eletrônicas.

Ainda na metade do século XVII a história registra o desenvolvimento de duas máquinas calculadoras. Blaise Pascal (1623 - 1662), matemático e filósofo francês, desenvolveu, para somar e subtrair, a Pascaline [MOR 84], [RAN 75], cuja operação lógica estava baseada em engrenagens, eixos, alavancas, etc. Pelo final daquele século o matemático alemão Gottfried Wilhelm von Leibniz (1646 - 1716) criou sua calculadora, com as quatro operações aritméticas.

A criatividade levou à lenta transformação das máquinas somadoras simples, a equipamentos calculadores, embora com lógica ainda puramente mecânica, mas relativamente sofisticados e com capacidade de realizar as quatro operações. Em última análise esta lógica consistia no engrenamento adequado de rodas dentadas acopladas a eixos, manivelas, etc. Um grande passo em direção à automação das máquinas foi dado pelo francês Joseph Marie Jacquard (1752 - 1834), que “memorizou” em cartões perfurados as seqüências de operações a serem executadas nos teares, pelos tecelões. Esta inovação foi reutilizada no século passado pelo americano Hermann Hollerith na sua máquina de tabulação, para o censo de 1900 nos EUA e mais tarde popularizou-se na indústria de informática.

É clássica a histórica “Analytical Engine”, máquina de aplicação geral, projetada pelo Inglês Charles Babbage. Nos dizeres da sua conterrânea Ada Byron, condessa de Lovelace, tal mecanismo poderia até compor músicas extensas e complexas. A acreditar-se nas palavras da Lady inglesa, esta seria a primeira máquina a que se poderia possivelmente

¹Em que pese o sentido *antropomórfico* aqui enfatizado, parece evidente que também há adoção destas leis nos demais reinos da Natureza.

chamar criativa, inteligente e isto em época ainda anterior ao advento da eletricidade e da eletrônica. Mas, as próprias palavras de Lady Ada, “A máquina Analítica não tem nenhuma pretensão de originar nada; ela pode fazer o que soubermos mandá-la fazer” [LUG 92], são parte do folclore da IA e como que profetizam a grande celeuma trazida pelo tema.

Babbage interessou-se por máquinas de processamento mais completo, supostamente devido à observação da variação automática de padrão de pontos de bordado conseguida com a simples mudança de posição de agulhas em um dispositivo semelhante ao de Jacquard, usado por mulheres bordadeiras, em saraus a que ele comparecia. Antes da Máquina Analítica, Babbage construíra a Máquina Diferencial, de aplicação específica, que podia calcular valores de algumas funções polinomiais, mas a Analítica tinha conceitos que podem ser comparados com os módulos funcionais dos modernos computadores digitais como: memória e processador separados (armazém e moinho, nos termos empregados então), conceito de representação digital, em lugar de analógico, programável através de série de cartões perfurados e, mais impressionante para aqueles dias, a idéia de que uma atividade puramente intelectual pudesse ser estudada e mecanicamente implementada.

George Boole [BOO 54] formalizou matematicamente, na hoje chamada Álgebra Booleana, as leis da lógica que embasam a Ciência da Computação. O advento da eletricidade possibilitou a motorização das calculadoras existentes, ainda com princípios de funcionamento lógico calcado sobretudo no acoplamento adequado de rodas dentadas, mas agora mais rápidas e de processamento mais poderoso, por serem eletromecânicas.

Em meados do século XX, a adoção de relés eletromagnéticos, seguidos pelas válvulas eletrônicas e posteriormente dos transistores, constituíram, sobretudo o último, saltos de qualidade que deslancharam na criação dos modernos computadores digitais. Estes tiveram, em pouco mais de cinquenta anos, uma evolução fantástica, iniciada com as máquinas programadas via modificações executadas no próprio hardware. O cientista húngaro naturalizado americano, John von Neumann teve o grande mérito no planejamento de uma máquina de concepção digital, com funções modularmente distribuídas em mecanismos de entrada, memória, processamento, controle e saída, sendo todo o processo gerenciado por um programa armazenado na memória do computador [PAT 97]. Esta dupla função da memória, de guardar não apenas os dados a processar, como as máquinas até então construídas, mas também a forma de processá-los, isto é, o programa, deu a grande flexibilidade que os computadores passaram a exibir com esta nova arquitetura, que ainda norteia a construção dos modernos computadores.

Linguagens de baixo nível, lógica baseada em válvulas, programação dependente de modificações na montagem de partes da máquina, caracterizaram a chamada 1ª Geração de Computadores. Posteriormente passou-se para transistores e linguagens de alto nível na 2ª Geração.

Os circuitos integrados e o software estruturado caracterizaram a 3ª Geração, a criação dos microcomputadores e das redes configuraram a 4ª Geração e hoje as máquinas que têm embutidas ferramentas de IA e linguagem natural poderiam ser ditas de 5ª Geração.

Alguns autores, como [CER 98], adotam uma ótica mais *funcional* e concentram a história da computação em quatro momentos chave: Nos anos 40 a transformação de uma ferramenta científica em um *produto comercial*; nos anos finais da década de 60 o surgimento de *sistemas* relativamente pequenos; os anos 70 marcaram o começo da *computação pessoal* e ao redor do ano 1985 as *redes de computadores* se fizeram presentes, notando-se uma verdadeira explosão no seu uso, com a popularização trazida pela *Internet* ².

2.1.3 Um sonho: a recriação da “máquina homem”

Ao longo da história observa-se que a criação de equipamentos de cálculo andou paralelamente com o desenvolvimento de outros mecanismos auxiliares como máquinas para andar, voar, costurar, plantar, navegar, etc. Parece que além da lei do menor esforço, obedece-se a outra, de validade mais geral, profundamente enraizada na espécie humana: “o homem procura ser deus”, pelo menos quanto ao aspecto do exercício do poder da criação.

O objetivo de criar, de fabricar o homem completo - corpo e mente - já existia, e, à medida que o progresso tecnológico avança e novas descobertas são agregadas ao conhecimento humano, tem-se a impressão de que ele se torna uma possibilidade real. Este desejo de domínio sobre a vida e sobre a morte é reconhecido nas lendas gregas desde que Prometeu formou os primeiros humanos a partir de bonecos, que fez de barro, deu-lhes vida e, com ajuda da deusa Atena, sua amiga, bafejou-os com “o espírito, o sopro divino” e depois ensinou-lhes a escrita, os números, a navegação, os remédios e “todas as artes que tornam a vida mais cômoda” [SCH 94]. Roubou ainda o fogo aos deuses do Olimpo e deu-o de presente à humanidade, que formara; tal dom mantê-la-ia viva. Este feito ilustra lendariamente a causa da iluminação da mente humana, o que teve como consequência, a longo prazo, a civilização atual, e é uma das explicações por que o fogo é, desde a antiguidade, associado às qualidades mentais.

Também é popularmente conhecida a promessa da serpente bíblica que no Livro do Gênesis, capítulo 3, versículo 5, fala: “... Porque Deus sabe que se comerdes desse fruto se abrirão vossos olhos e vós sereis como uns deuses, conhecendo o bem e o mal” [BÍB 87]. Tanto na lenda grega como na história bíblica, a coisa acabou mal para os protagonistas. Em razão de sua audácia, Prometeu foi acorrentado por Zeus, deus dos deuses, a um penhasco das montanhas do Cáucaso, onde uma águia vinha comer-lhe o fígado. Adão e Eva foram expulsos do paraíso terrestre e até hoje o ser humano se lamenta da grande asneira constituída pelo “pecado original”, cometido pelos pais bíblicos, a quem se imputa a tragédia de terem trocado por uma mísera maçã, os prazeres de uma “dolce vita” terrena.

O intervalo de tempo decorrido entre o fim da civilização grega - muito copiada e difundida pelo império romano - e o fim da Idade Média, não foi muito produtivo para as ciências, letras e artes em geral. Nos séculos XV e XVI, com o movimento conhecido por Renascimento, a ciência, as letras e as artes tiveram grande impulso, retomando um movimento fértil que havia caído em letargia durante a Idade Média, depois dos avanços

²www: world wide web.

consideráveis obtidos sobretudo pelos gregos. Para exemplificar, destaca-se aqui Leonardo da Vinci (1452 - 1519), livre pensador, que, com suas máquinas e suas idéias é, com certeza, um marco importante nesta história, pelo fato de ter se engajado profunda e proficuamente, tanto na produção artística e filosófica, quanto na idealização de mecanismos que ajudassem o homem em sua vida, como projetos de barco a vela, submarino, avião, helicóptero, pontes e ainda com estudos de anatomia e de fisiologia.

Apenas com o advento da Revolução Industrial, a partir do século XVIII, tornou-se possível a materialização de muitos dos sonhos de da Vinci e de outros estudiosos.

No século XIX e no início do XX se deu também um estupendo salto em termos científicos e tecnológicos de interesse para a IA, como a descoberta da eletricidade, das telecomunicações, de novos materiais, avanços na Medicina, Biologia, etc. Como consequência se teve maiores conhecimentos sobre o funcionamento do corpo, com a descrição científica do sistema digestivo, locomotor, circulatório, nervoso, etc.. Também, com a ajuda de melhores técnicas e instrumentos, se fizeram pesquisas que individualizaram o neurônio [HUB 79] e se estabeleceu em bases sólidas a Biologia Molecular, o que tem reflexo direto na área de interesse deste trabalho. A importância destes avanços se torna mais evidente quando se lembra que os gregos, por exemplo, tão avançados em estudos filosóficos, geométricos e artísticos, chegaram a locar a mente humana no coração, no fígado! Mesmo Descartes, dois milênios depois, diz que a mente advém da glândula pineal [POP 77].

Nota-se que é recorrente a noção de que os esforços humanos para a busca do saber constituem-se em uma arriscada aventura, em terrenos proibidos que aos deuses pertencem. Parece que ela está, todavia profundamente plantada na civilização ocidental, e, além da Bíblia e das conhecidas lendas gregas, aflora à superfície em autores famosos, como Dante e Milton, entre outros. [LUG 92].

Mas a humanidade gosta de correr riscos. Tendo já projetado e construído tantas máquinas, por que não criar uma que fosse feita à sua “imagem e semelhança”? Se ainda não se sabe como criar outro humano, pelo menos se tenta fabricar um mecanismo que o simule tão bem quanto possível. Afinal já se detém tanta experiência na manufatura de sistemas mecânicos complexos, e ainda, o corpo humano pode ser, em grande parte dos seus aspectos, visto como uma máquina, embora nem sempre só mecânica. Também em termos de processos biológicos e de materiais constitutivos, supostamente se teria conhecimentos suficientes para o lançamento de um projeto que, em última instância, desembocaria na criação de um ente que seria a duplicata do homem. E agora, com auxílio de ferramentas tão poderosas e versáteis como o computador, esta criação seria não somente cópia funcional de seus componentes biológicos e ou mecânicos, mas também do seu órgão mais complexo, o cérebro.

Marvin Minsky, do Massachusets Institute of Technology, um dos mais renomados cientistas engajados nesta colossal tarefa, diz textualmente: “a próxima geração de computadores será tão inteligente que teremos muita sorte se eles permitirem manter-nos em casa como animais de estimação domésticos” [SEA 84]. Deve-se deixar claro desde já que, apesar da promessa embutida na citação de Minsky, mesmo os cientistas mais otimis-

tas têm como certo que os conhecimentos científicos e tecnológicos ora detidos pela humanidade, em termos de fenômenos físicos, químicos, biológicos, neurológicos e outros, são insuficientes para construir um homem artificial. Grande parte dos pesquisadores já se dariam por muito felizes se conseguissem desenvolver uma máquina de processamento digital que exibisse inteligência, na acepção que se discutirá neste trabalho. Mas permeia a crescente produção científica da área muita confusão terminológica, sendo um grande problema, o uso de termos inadequadamente colocados ou de sentido pouco preciso, que podem levar a interpretações errôneas.

Conseqüentemente se pode afirmar que este é um aspecto relevante de pesquisa em IA que deve ser empreendido brevemente para homogeneizar os conceitos e o vocabulário técnico da área. Para citar apenas dois exemplos, John McCarthy diz que “máquinas tão simples como termostatos têm - pode-se dizer - crenças”, assim como quase toda máquina capaz de resolver problemas. E, a título de esclarecimento, reafirma “o meu termostato tem três crenças - está demasiado quente aqui, está demasiado frio aqui e está bem aqui” [SEA 84]. Alan Newell diz que “já temos máquinas que podem pensar”, literalmente. Esclareça-se que a John McCarthy é atribuído a criação da expressão Inteligência Artificial, no Dartmouth College, em reunião com outras personalidades da área, como Marvin Minsky, Alan Newell e Herbert A. Simon, em 1956 [BAR 01].

Parece que se as máquinas podem pensar, ter crenças e se sabe o que é a inteligência, a sorte a que se refere Minsky na frase acima transcrita, está, como uma espada de Dâmocles, suspensa por um delgado fio sobre a cabeça da humanidade. No afã de criar métodos mais fáceis para executar seus trabalhos o homem sofreria a maldição de desenvolver um ser que o subjuga: a criatura se voltaria contra o criador.

Se desejamos criar substâncias, máquinas, processos que facilitem nossa existência e que, às vezes, incidentalmente exibam inteligência, nos substituam, pelo menos em algumas tarefas, é muito importante que se saiba “*quem somos, de onde viemos, para onde vamos*”. Estes problemas filosóficos têm sido objeto de estudo há milênios e, na seqüência, alguns aspectos que se referenciam a este trabalho serão abordados. Os pressupostos filosóficos em que se fundamenta a pesquisa científica são importantes e, na área da Ciência da Computação há trabalhos que exploram este veio, como o de A. C. Rocha Costa [COS 93].

2.1.3.1 Quem somos?

A máxima “Conhece a ti mesmo”, lançada há mais de 2400 anos por Sócrates (469? - 399 AC), nos seus famosos “Diálogos” transcritos por Platão, continua hoje tão válida quanto nos dias do grande filósofo de Atenas. Muitas pequenas luzes foram acesas na pesquisa das respostas dos temas acima, mas, parece que à medida que se avança iluminando o “túnel”, mais extenso ele fica, mais distante fica seu fim.

Relativamente à primeira indagação, “Quem somos?”, apesar dos promissores avanços no conhecimento do corpo humano, sua constituição, seu funcionamento, seus problemas ainda são campo quase totalmente aberto à ciência. Em outras palavras, como é

feito nosso corpo e nossa consciência? Como funciona? Por que envelhecemos? Como evitar ou curar as doenças que nos afligem? São algumas indagações ainda mal respondidas ou de solução completamente ignorada, tanto que nos últimos dias do século XX a descoberta do genótipo humano é, pasme-se, um dos maiores objetivos da ciência biológica. De fato, um dos maiores programas governamentais de pesquisa científica da atualidade é o Projeto Genoma Humano, iniciado em fins da década de 80, com o objetivo de mapear a sequência dos nucleotídeos formadores dos genes - segmentos conhecidos das moléculas de DNA - que são responsáveis pela síntese das proteínas necessárias aos seres vivos. O principal financiador deste projeto é o NIH, Instituto Nacional de Saúde dos EUA ([MAR 96]) e nele um esforço superior a US\$3 bilhões foi alocado, tendo sido publicado em fins de junho de 2000 um “rascunho” deste imenso trabalho. Mas, ainda mais desafiadoramente, tem-se as profundas indagações: somos apenas corpo, matéria, ou, em nossa constituição há ‘algo mais’, transcendente, imaterial?

Quem somos? a resposta à pergunta tão simples e curta tem ocupado e preocupado as melhores mentes desde tempos imemoriais. Os antigos gregos, nos legaram documentos explicativos. Demócrito (460?-370 A . C.) “presumiu que todas as coisas eram constituídas por uma infinidade de pedrinhas minúsculas, invisíveis, cada uma delas sendo eterna e imutável. A estas unidades mínimas Demócrito deu o nome de átomos. ... Mas o que acontece com a consciência? Demócrito acreditava que a alma era composta por alguns átomos particularmente arredondados e lisos, ‘os átomos da alma’” [GAA 95, POP 77].

Quanto ao lado mental, parece que muito pouca coisa se sabe. Talvez inspirado nos gregos, em anos mais próximos a nós, René Descartes (1596 - 1650) criou toda uma obra bem formalizada, dividindo o mundo em dois tipos de substâncias: as mentais e as físicas. Estas eram domínio da ciência e aquelas da religião. Portanto, de acordo com a escola cartesiana, do século XVII, o homem é composto por corpo - sua parte física - e mente, ou alma, ou espírito - sua parte imaterial. A esta concepção chamou-se *dualismo*. Hoje poucos cientistas, tais como Eccles e Popper [POP 77] sustentam a teoria dualista cartesiana de que o espírito e a matéria são dois subsistemas diferentes que interagem. Seria talvez impossível fazer uma máquina que aja de modo semelhante ao ser humano se a inteligência, a consciência e o pensamento exigissem uma componente espiritual no seu funcionamento.

A outra corrente, que aceita apenas um elemento na composição do mundo, inclusive do homem, foi cognominada *monismo*. Existem várias outras tendências filosóficas, cada qual com suas divisões e subdivisões. Tem havido intensa polêmica, ao longo dos séculos, entre os pensadores de cada linha. Por exemplo, Searle [SEA 84] diz que um de seus objetivos é de “tentar acabar com as velhas categorias esgotadas da Filosofia da mente”, de acordo com as quais se pode ser “monista ou dualista. Se for monista, pode-se ser materialista ou idealista. Se for materialista se pode ser behaviorista ou fisicalista. E assim por diante”. Não é objetivo deste trabalho entrar em detalhe neste campo. Apenas para ilustrar, resumidamente, “... o idealismo diz que o espírito é eterno, infinito, primeiro: a matéria deriva dele e os fenômenos do universo se devem à forças imateriais, ao espírito”.... Do lado oposto, o materialismo diz que “a matéria é eterna, infinita, primeira e origina o espírito. Os

fenômenos do universo são os diversos aspectos da matéria em movimento” [ARA 93].

Geralmente os pesquisadores em IA e de ciência cognitiva rejeitam o dualismo cartesiano, teorizando ser a consciência explicável através de um modelo material baseado na implementação física de símbolos. Outros dizem que a mente é a emergência da interação de aproximadamente 100 bilhões de neurônios que compõem o cérebro humano ³.

Minsky e Papert [MIN 88a] sugerem que a mente é constituída de um grande número de estruturas especializadas, funcionando em paralelo, com algum mecanismo de controle serial. Aliás, em alto nível já se sabe que o cérebro é composto por dois hemisférios separados que trabalham em atividades bastante definidas, sendo o direito intuitivo, criativo, não verbal e o esquerdo mais lógico, verbal e de desempenho simbólico.

Está portanto ainda em aberto a questão “*quem somos*” e mesmo que o ser humano seja só matéria, esta é mal conhecida até agora e as questões relativas à inteligência, tais como: o que é, como funciona, como surge, etc., estão encerradas em uma caixa preta. O conhecido problema corpo-mente resiste quase intocado. Obviamente os pesquisadores da área optam por uma ou outra tendência e “com todo este desacordo sobre o quê constitui a inteligência, o pensamento e o entendimento, será necessário algum tempo, antes que definições satisfatórias sejam produzidas” [TVE 98]. Entretanto, o autoconhecimento do ser humano, necessário para a criação de novos entes, passa necessariamente pelo estudo do problema de seu passado e de seu futuro.

2.1.3.2 De onde viemos? Para onde vamos? Alguns enfoques de estudo

Dois enfoques entre os possíveis serão adotados para abordar este tema: o *evolutivo* e o “*físico*”. De um lado se tem leis que procuram explicar a vida e de outro leis que tentam desvendar os fenômenos que ocorrem com a matéria.

Enfoque evolutivo

O *enfoque evolutivo* é o direcionamento mais adotado pelos cientistas modernos para explicar o universo em que habitamos. Pela sua importância e por ser o fulcro em torno do qual se alavanca todo este trabalho, o tema foi postergado para ser mais aprofundadamente abordado no Capítulo 3.

Enfoque “físico”

Descobrir e compreender as leis que governam o funcionamento da Natureza como um todo, isto é, do Universo, seria uma possibilidade de se conseguir respostas às duas indagações “*de onde viemos?*” e “*para onde vamos?*”. Da mesma forma com que Sócrates instava seus discípulos com o “conhece a ti mesmo”, o nobelista Ilya Prigogine constata que “compreender a Natureza foi um dos grandes projetos do pensamento ocidental” [PRI 85].

De fato, novamente voltando às raízes gregas, sabe-se que no século VI AC, em Mileto na Ásia Menor, então parte da Grécia, uma escola de sábios designou “*physis*” à

³O termo cérebro é utilizado neste texto com a acepção de encéfalo, a parte do sistema nervoso central, contida no interior do crânio.

essência das coisas, não tendo um termo especial para designar a matéria, pois até então o mundo era concebido com uma concepção monista.

Pelo século V AC, os filósofos gregos da linha atomista diferenciavam espírito e matéria, sendo esta constituída por “blocos básicos de natureza morta” e daí se originou o dualismo. Feita a divisão, estes filósofos imediatamente optaram pelo estudo do mundo imaterial, a parte nobre da Natureza, sendo que o filósofo macedônico Aristóteles (384 - 322 AC) [GRA 76] organizou todo o conhecimento científico até então existente, deixando claro sua preferência: As questões da alma. Esta opção foi alegremente aceita pelos estudiosos que o sucederam e também encampada pelos seguidores da doutrina da Igreja Cristã, que teve grande predomínio no mundo ocidental civilizado de então, até a época do Renascimento, no século XVI. Neste intervalo de quase dois mil anos, as ciências entraram em estágio de hibernação.

Galileu Galilei (1564 - 1642), natural de Pisa, físico e astrônomo, foi um dos grandes responsáveis pelo fim da letargia bi-milenar e é tido como o primeiro a se interessar pelo estudo da Natureza, com abordagem científica: aliando a experiência prática às idéias teóricas e ao uso da matemática. Seguindo as idéias do astrônomo polonês Nicolau Copérnico (1475 - 1543) e observações telescópicas próprias, explicou que a terra não era o centro do sistema imóvel do universo, ao redor da qual os astros se moviam presos a esferas transparentes de cristal - como afirmava Aristóteles - mas girava ao redor do sol. Galileu mostrou enfaticamente a diferença entre o mundo em si mesmo e as idéias que dele se faz.

Embora Galileu não mencione, é quase certo que tenha tido algum contato com as idéias de seu compatriota e conterrâneo Giordano Bruno (1548 - 1600), um ex-frade que percorreu diversas cidades da Europa divulgando seus conceitos filosóficos originais, junto com os achados de Copérnico, o que devia provocar risos a um mundo para quem o filósofo estagirita era inquestionável. Pregava ainda que “Deus e a Natureza são uma só coisa; matéria e espírito, corpo e alma são duas fases da mesma substância; o universo é infinito e além do mundo visível há outros mundos, habitados” [MAS 99], adicionando ainda que o Espírito Santo é a alma do mundo e Cristo não é Deus, mas um mero mágico, embora muito habilidoso. Apesar das oportunidades incomuns que lhe foram dadas, não abjurou os erros teológicos que lhe imputavam e foi queimado vivo pela Inquisição, a 17 de fevereiro de 1600. No seu livro “Causa, Princípio e Fim” diz: “Não há limites ao alto ou embaixo, como ensinou Aristóteles; não há posição absoluta no espaço, mas a posição do corpo é relativa à dos outros corpos”, o que Einstein retomaria três séculos depois em sua teoria. Outra frase, que profeticamente parecia endereçada a Descartes, já que escrita cinco anos antes de seu nascimento: “Quem se preocupa com Filosofia tem que trabalhar pondo tudo sob dúvida”⁴.

Descartes já havia implantado um corte claro na Natureza, denominando as duas partes assim obtidas de *mente* e *matéria*⁵, sendo que esta era consubstanciada em objetos que interagiam como numa máquina de grandes proporções: o universo. Este matemático e filósofo francês tentou embasar seus estudos do mundo na introspecção pura, rejeitando

⁴“Who so itcheth to Philosophy must set to work by putting all things to the doubt”.

⁵“res cogitans” e “res extensa”, respectivamente.

as informações advindas dos sentidos como “inconfiáveis”, e assim duvidando da própria existência do mundo e aceitando inicialmente a realidade do seu próprio pensamento. Seu famoso silogismo “penso, logo existo”⁶, estabeleceu sua existência como entidade pensante e inferiu a existência de Deus e por consequência do mundo, sua criação.

Isaac Newton (1642 - 1727), por sua vez, formulou matematicamente as leis que explicaram o funcionamento do universo mecanicista cartesiano até o fim do século XIX. Para Newton, todos os fenômenos físicos tinham lugar em um espaço tridimensional absoluto, em repouso e imutável, sujeito aos teoremas da geometria euclidiana e as mudanças nele verificadas eram descritas em termos de uma grandeza separada: o tempo. Este também era assumido como absoluto e desvinculado do mundo, fluindo uniformemente, do passado para o presente, em direção ao futuro.

Neste palco hipotético os componentes da “máquina” cartesiana se mantinham ligados pela força gravitacional, obedecendo no seu movimento às leis da mecânica clássica. Deus criara as partículas materiais que formavam a terra e os corpos celestes, a força que as unia e as leis que regiam seu movimento, estando o universo sujeito a ditames eternos que permitiam, dadas as condições iniciais de um determinado fenômeno, tanto predizer o futuro quanto retrodizer o passado. O matemático e astrônomo francês Pierre Simon, marquês de Laplace, expressou de forma forte e cristalina esta crença: “Uma inteligência que, num instante dado, conhecesse todas as forças de que a natureza é animada e a situação respectiva dos seres que a compõem, se, por outro lado, fosse bastante ampla para submeter esses dados à análise, incluiria na mesma fórmula os movimentos dos maiores corpos do universo e os do mais leve átomo; nada seria incerto para ela, e, tanto o futuro como o passado, seriam presentes aos seus olhos”. [HUI 64]. Em outras palavras, dadas as posições das partículas num dado instante e as leis que governam seus movimentos, se conheceria a história pretérita e futura do universo. Estariam respondidas as questões “*de onde viemos*” e “*para onde vamos*”.

Laplace, na sua famosa coleção “*Mécanique Celeste*” [LAP 69], aplicou as leis de Newton para explicar pormenorizadamente o movimento dos corpos do sistema solar e mostrou que elas lhe asseguravam uma estabilidade auto-reguladora.

Tendo servido maravilhosamente bem para os fenômenos físicos terrestres e também para os corpos celestes conhecidos até então, a Mecânica Newtoniana também se mostrou ótima ferramenta para explicar o movimento dos fluídos, das vibrações elásticas e até fenômenos térmicos. Entretanto, no início do século XIX, Michael Faraday (1791 - 1867) e James C. Maxwell (1831 - 1879), descobriram fenômenos elétricos e magnéticos, como atração entre cargas positivas e negativas, não explicáveis via uma força simples, como a gravitacional. Então teorizaram que tais cargas criam uma situação no espaço que as rodeia, de tal forma que outra carga nele localizada sofre uma força. Denominaram campo a esta condição, que existe mesmo na ausência de outra carga para experimentá-lo. Os campos têm existência própria e não precisam estar ligados a corpos, como as forças propostas por Newton e assim a luz, as ondas de rádio e todo o espectro eletromagnético são campos elétricos

⁶ “cogito, ergo sum”.

e magnéticos que podem percorrer o vácuo, sem que se possa explicar mecanicamente o fenômeno.

No início do século XX Albert Einstein (1879 - 1955) desenvolveu a Teoria Especial da Relatividade, interligando os campos da Física Clássica, isto é, da Mecânica e da Eletrodinâmica. Nesta teoria o espaço não é mais tridimensional, como o newtoniano, mas forma com o tempo um todo intimamente interligado, quadri-dimensional, chamado espaço-tempo. Em 1915, em nova proposta, expôs a Teoria Geral da Relatividade, generalizando a Teoria Especial, de modo a englobar a força gravitacional e mostrando que, nos casos de corpos suficientemente compactos, esta força curva o espaço ao seu redor. Hoje, *sempre que se trabalha com fenômenos que envolvem velocidades próximas à da luz*, a teoria da relatividade deve ser acionada e nela eventos A e B que, para um observador parecem ser simultâneos, podem ser ordenados como A tendo ocorrido antes de B por outro observador que se move a velocidade diferente com relação aos eventos e mesmo com B antes de A, por um terceiro observador, tudo dependendo de sua velocidade em relação aos fenômenos. Com isto se vê que o espaço e o tempo absolutos de Newton, não valem neste “*novo mundo*”, permanecendo apenas como elementos explicativos. Os conceitos de espaço, tempo, inércia dos corpos e energia, da Física Newtoniana, ruíram com a descoberta que o tempo se dilata, passa mais devagar para alguém que viaja à velocidade comparável à da luz. O espaço se contrai, diminuindo os corpos animados com altas velocidades e para estes também a energia cinética faz com que aumentem sua inércia e também sua massa.

Em 1900 o físico alemão Max Planck (1858 - 1947), notou que a emissão de energia térmica por um corpo negro não se dava de forma contínua, mas aos saltos, como em pequenos “grânulos” a que, posteriormente, Einstein denominou “quanta”. Partindo desta descoberta, um grupo internacional de físicos desenvolveu a Teoria Quântica, onde os elementos subatômicos têm aspecto dual: podem aparecer como partículas ou como ondas, da mesma forma que a luz, os elétrons e até as moléculas, que também manifestam a mesma propriedade.

Uma consequência extremamente importante advinda da teoria quântica é que ela, como já fizera a relatividade, também ajudou a abalar os alicerces da Mecânica Clássica, tirando-a do pedestal que majestaticamente ocupava, desde o século XVII. De fato, no mundo dos átomos ou das partículas elementares que os compõem, viu-se que a Mecânica Clássica era insuficiente ou mesmo contraditória o que motivou o desenvolvimento da Teoria Quântica. Nesta teoria, o princípio da incerteza, de Werner Heisenberg [PRI 85], afirma que é possível medir a coordenadas da posição relativa de uma partícula em um sistema, bem como sua *quantidade de movimento* (produto de sua massa m pela sua velocidade v), mas não simultaneamente. O princípio de Heisenberg expressa que, no nível subatômico, jamais se pode afirmar com certeza que a matéria existe em determinado lugar mas sim que ela pode ocorrer, com tal ou qual probabilidade. Vê-se assim a incompatibilidade fundamental entre a afirmativa de Laplace e a de Heisenberg.

As leis de Newton poderiam dar a impressão, e de fato deram ao menos para alguns cientistas, que o Universo era regido por leis físicas imutáveis, claras, bastando

seu conhecimento e aplicação correta para se escrever a história passada e futura, respondendo assim às duas indagações iniciais. Conforme esta aceção, adotando a nomenclatura científica, dir-se-ia que o Universo é determinístico: conhecendo-se as causas, poder-se-ia prever os efeitos.

Por outro lado, a Teoria da Relatividade, também abalou os alicerces newtonianos determinísticos pois demonstrou que as Leis de Newton não se adequam aos fenômenos da observação cosmológica, dos “grandes objetos celestes” e nem aos relacionados às partículas subatômicas, como demonstram os fatos descobertos no século XX, que originaram a criação da Física das Partículas ou Física de Alta Energia. Tanto a nível macroscópico, como a nível microscópico, ficou claro que, estando os objetos de estudo sujeitos a velocidades próximas à da luz, as leis de Newton não serviam para explicar os fenômenos da Natureza, embora sendo muito úteis para observar os fenômenos do “dia a dia”, do mundo visível, funcionando a velocidades distantes daquela da luz. Porém as modernas Teoria da Relatividade e Teoria Quântica trazem algumas respostas, mas abrem novas indagações.

Um dos objetivos primeiros e ainda básicos em física é o de se encontrar uma teoria básica universal, completa, que englobe a explicação de todos os fenômenos físicos. Os físicos chamam-na “teoria de tudo”. Ainda alguns cientistas persistem em buscar os “blocos elementares indestrutíveis e imutáveis que formam a matéria” [CAP 83], apesar de se ter indicações fortes de que este conceito não se sustenta, uma vez que se mostrou a criação de partículas, advindas da transformação da energia cinética, podendo, de modo inverso, também as partículas se transformar em energia.

Há teorias, como a de David Bohm ou a de Geoffrey Chew, que procuram explicar as relações entre consciência e matéria dentro do contexto científico [BOH 51]. Bohm concebe “mente e matéria como dependentes e correlatas, embora não ligadas casualmente”.

Percebe-se que a temática até aqui tratada é totalmente focada sob o ponto de vista da ciência ocidental, que por sua vez deriva de linhas levantadas ainda nos tempos da civilização grega - que muito herdou da egípcia. Este também sugou idéias de outros povos com quem tinha contatos comerciais ou mesmo bélicos - por exemplo o império macedônico de Alexandre englobou toda a península grega, a Ásia e se estendeu a pontos da Índia e da China. Apesar das três teorias principais aqui relacionadas como pilares da ciência moderna - mecânica newtoniana, quântica e relativística - serem de origem ocidental, hoje se nota um retorno ao holismo, “ao místico” [CAP 83] que sempre tem sido o prisma pelo qual o Oriente explica o mundo. Com efeito, já há mais de três mil anos os chineses acreditavam que existe uma energia vital que anima o cosmos, a que denominaram *Chi*, superior a todas as coisas do universo. Nesta concepção existem dois tipos de *Chi*, o *Sheng Chi*, energia benéfica e o *Sha Chi*, representando a energia de desarmonia. Nas palavras de Fritjof Capra [CAP 83], “o *Chi* é concebido como uma forma tênue e não perceptível de matéria, presente em todo o espaço e que pode condensar-se em objetos materiais sólidos ... À semelhança do que se verifica na teoria quântica dos campos, o campo - o *Chi* - não é apenas a essência subjacente a todos os objetos materiais como, igualmente, transporta suas interações mútuas sob forma de ondas”.

Em [ROS 99] se encontra a concepção chinesa para a mente, o “*eu não biológico*”, imaterial, desenvolve-se a partir do “*ling*”, que são partículas embrionárias, elementares. Esta concepção lembra o que Demócrito ensinava [GAA 95]. A busca por modelos que expliquem quem o homem é, qual seu passado e qual seu futuro é recorrente e universal, como se vê.

Um modelo, uma teoria, serve para averiguar o que ocorreu no passado, explicar o que ocorre no presente e predizer o que ocorrerá e se ela faz isto bem, deve ser boa [KUH 62]. Todavia diferentes modelos podem explicar diferentes aspectos de um fenômeno.

De fato, por exemplo, o “espírito” (mente, razão) foi sucessivamente comparado a um moinho (por Leibniz). Posteriormente achou-se que um sistema hidráulico se assemelhava mais ao trabalho do cérebro. Com o advento das telecomunicações, uma mesa comutadora de telefonia seria o modelo mais adequado [SEA 84]. Hoje o sistema fabricado pelo homem, que pode simular o que se presume ser o funcionamento do cérebro é o computador. Entretanto as estruturas holográficas, que têm a característica de manterem sua essência informativa mesmo quando são seccionadas, parecem mais adequadas a representar o funcionamento cerebral, visto que, mesmo morrendo parte dos seus neurônios componentes, a faculdade mental não sofre degradação importante. Com os conhecimentos atuais da Informática, da Psicologia, da Neurologia, da Genética, da Biologia Molecular e outras ciências e com a velocidade com que novos progressos são alcançados, alguns importantes componentes de renomados grupos de pesquisa vislumbraram a possibilidade de se ter em horizonte de tempo não muito longo, computadores que podem ser chamados inteligentes.

2.2 O QUE É A INTELIGÊNCIA

2.2.1 Aspectos “Físicos” da Inteligência

A característica evolutiva que mais influenciou o estupendo sucesso alcançado em tão pouco tempo pela espécie humana (admitindo-se a hipótese evolucionista), que no intervalo relativamente pequeno de aproximadamente 100.000 anos (Figura 2.1), dominou praticamente todos os ambientes terrestres e já se lança à exploração do espaço extra-terrestre, foi sem dúvida sua inteligência.

Os 1.200 cm³ de massa cinzenta da espécie humana, com certeza restituíram muitas vezes seu peso em termos de progresso aos “seus donos”. De fato, desde as savanas africanas, onde grande parte dos pesquisadores atuais situam o surgimento do *Homo sapiens* [MIT 00], este se aventurou em ambientes bem mais agressivos, sob certos aspectos, que aquele continente quente, como as regiões temperadas ou mesmo muito frias, ilhas oceânicas, etc. sempre se adaptando e evoluindo. É bom frisar que o fato de que ter que se defrontar com obstáculos impostos pelo meio, como o frio, a água, as florestas, o gelo, etc. fez com que o homem crescesse sempre, em sabedoria, mostrando que quanto mais exigida era sua inteligência, mais correspondia às necessidades.

Mas o que é a inteligência? Pode-se estudá-la sob o ponto de vista fi-

losófico, físico, computacional, psicológico e outros. Aqui, sobretudo o aspecto computacional interessa, mas, para situar o contexto, também os dois primeiros serão abordados. Além do estudo da inteligência do ponto de vista filosófico, que já era ordem do dia no tempo em que Aristóteles definiu o homem como “um ser racional”, portando atribuindo-lhe dogmaticamente a característica de exibir a condição dual: *é material* - é um ser - e também é imaterial: *é racional*. Adicionalmente Aristóteles traçou também assim uma linha demarcatória clara: por exclusão, por não citar, definiu de certa forma que os outros entes que conhecia e que entendia como seres, a saber, talvez, os animais e as plantas (e os deuses!?), não eram racionais. Novamente estes são hoje motivo de controvérsia e um grande esforço deve ser dispendido pela comunidade científica da área, para aclarar ou por em níveis de nomenclatura minimamente “padronizada” os trabalhos sobre o assunto.

Tendo este trabalho seu maior centro de interesse na IA, os aspectos físicos, tecnologicamente implementáveis em máquinas, devem ser prioritariamente tratados. Muitos cientistas têm se esforçado para encontrar soluções para o problema *mente-corpo* e a Teoria Quântica tem sido particularmente invocada para uma explicação física da consciência, já que, como foi procurado à exaustão, de modo infrutífero, é improvável que ela surja das propriedades clássicas da matéria, se bem que esta via seja às vezes tomada por terem, tanto a consciência quanto a Teoria Quântica, um grau de mágica que as torna misteriosas e inatingíveis.

O físico americano Henry Stapp [STA 93] sustenta que a Física Clássica não pode explicar a consciência, porque nela o todo não pode ser maior que as partes e então só a Física Quântica poderia se candidatar à tarefa. Evan H. Walkers [WAL 00] teorizou um modelo quântico em que o “tunelamento” (passagem de partículas por barreiras que normalmente seriam intransponíveis) de elétrons entre neurônios adjacentes, cria uma rede neural virtual sobreposta à real, e responsável pela consciência. A rede neural real obedece às leis clássicas e a virtual às quânticas.

Roger Penrose [PEN 94], dos mais renomados físicos britânicos atuais, é dos fortes entusiastas da consciência baseada na Mecânica Quântica, e faz a conjectura de que ela seja a manifestação do estado quântico do cito-esqueleto - estrutura constituída de proteínas cilíndricas ocas formando micro tubos de diâmetro ao redor de 25 nanômetros - que controla as sinapses. Ian N. Marshall [MAR 91] aventa a hipótese de que a consciência possa se originar da excitação de condensados de Bose-Einstein [ROB 01]. Estes são fenômenos quânticos de mudança de fase apresentados pelos átomos de algumas substâncias que, quando resfriadas a temperaturas suficientemente baixas (próximas ao zero absoluto) se comportam de forma coerente e conjunta. Os trabalhos nesta área vêm tendo interesse crescente, como atesta a premiação dos nobéis em Física de 2001, E. A. Cornell, W. Ketterle e C. E. Wieman, devido aos primeiros estudos fundamentais das propriedades destes condensados.

O psicólogo Karl Pribram [PRI 90] sugere o modelo de holograma onde as percepções sensoriais provocam “ondas cerebrais”, um tipo de ativação eletromagnética que se propaga no cérebro e cuja interferência mútua provoca o efeito de holograma, quando uma “onda de memória” se encontra com uma “onda sensorial”. O filósofo americano David

Chalmers [CHA 96] defende um novo tipo de monismo em que o mundo teria características físicas e não físicas; mas com aceção diferente da cartesiana. Para ele, além do espaço-tempo, massa, carga, etc., outra grandeza fundamental, ainda desconhecida, seria acrescida às existentes, juntamente com as leis “psicofísicas” correspondentes.

2.2.2 Aspectos “psicológicos” da Inteligência

Sob o prisma psicológico, um autor muito em voga nestes dias, Howard Gardner [GAR 94] propõe um conjunto de sete inteligências básicas:

- i) Inteligência lingüística;
- ii) Inteligência musical;
- iii) Inteligência lógico-matemática;
- iv) Inteligência espacial;
- v) Inteligência corporal-cinestésica;
- vi) Inteligência intra-pessoal;
- vii) Inteligência inter-pessoal.

Da mesma forma que, com sete notas, se fazem infinitas músicas, com estas inteligências fundamentais se compõem tantas ‘inteligências resultantes’ quantas se queira. Para isolar as sete básicas, Gardner apresenta oito pré-requisitos:

- Isolamento potencial por dano cerebral;
- Existência de “idiots savants” (idiotas prodígio): indivíduos excepcionais em alguns domínios e medíocres em outros;
- Operação central ou conjunção de operações identificáveis;
- História desenvolvimental distintiva, aliada a um conjunto definível de desempenhos proficientes de ‘expert’ (“estado final”);
- História evolutiva e a plausibilidade evolutiva;
- Apoio de tarefas psicológicas experimentais;
- Apoio de achados psicométricos;
- Susceptibilidade à codificação em um sistema simbólico.

Gardner acha que todo indivíduo tem em maior ou menor grau uma certa dosagem de cada uma delas, podendo desenvolver umas mais, outras menos, conforme aspectos hereditários aliados a treinamento precoce.

No início dos anos 90 Daniel Goleman trouxe a “inteligência emocional” [GOL 95], com a idéia de que o sucesso do indivíduo depende da empatia, compaixão e da habilidade que se tem em responder à dor ou ao prazer, sendo a base para um bom uso do QI (Quociente de Inteligência - “*IQ - Intelligence Quotient*”) tradicional. Os autores Danah Zohar, da Universidade de Oxford e o psiquiatra Ian N. Marshall [ZOH 00] dizem que a antiga “inteligência racional” medida com o QI e a ‘nova’, emocional (talvez mensurável com o QE - Quociente Emocional!, “*EQ - Emotional Quotient*”) dependem de uma terceira,

mais fundamental, a “inteligência espiritual”, medida pelo QS (Quociente Espiritual - “SQ - *Spiritual Quotient*”). Para eles, os computadores têm alto QI, os animais podem ter alto QE, mas apenas os humanos exibem o QS, habilidade para ser criativo, mudar regras, alterar situações e perguntar “*quem somos?*”.

Enfim, tem-se tantas explicações para o enfoque “físico” quantas para o “psicológico” e a famosa frase de Theodosius Dobzhansky “Nada na Biologia tem sentido, exceto sob a luz da evolução” deve, para alguns cientistas, ser estendida à Psicologia, ciência que estuda os padrões de comportamento e de pensamento. Nesta linha eles propõem a Psicologia Evolucionária [PIN 97], que se baseia na hipótese que a mente é feita de órgãos, com papéis específicos e afirma:

1. Cada um destes órgãos é uma ‘adaptação’, isto é, uma característica que direta ou indiretamente levou à melhora do organismo na habilidade de produzir descendência mais adaptada;
2. A seleção natural foi a força motriz na formação destes órgãos mentais;
3. Isto foi feito no período evolucionário em que nossos ancestrais eram caçadores-coletores da savana africana.

Também nesta linha de atuação, em “Sociedade da Mente”, Minsky propõe um modelo em que a inteligência consiste de uma comunidade de agentes cooperativos especializados, cada qual com seu papel, que pode ser o entendimento de dados visuais, comunicação em linguagem natural e demais atividades mentais [MIN 85]. Jerry A. Fodor [FOD 83], Daniel C. Dennett [DEN 91], entre outros, acompanham esta sugestão.

2.3 A BUSCA DA IA

2.3.1 Introdução

Se o homem é feito da mesma matéria que constitui o universo, se a inteligência é oriunda da organização desta matéria, se se conhecem as leis que regem a constituição e o funcionamento desta matéria, então, pelo menos teoricamente, seria humanamente possível construir um ser que tivesse inteligência. E, por ser fabricado, teria “Inteligência Artificial”. É pois necessário que se esclareça o que se entende por Inteligência, para que, à medida que se avança na construção de mecanismos, materiais e processos mais sofisticados, se saiba quando se chegou a uma máquina que exiba os requisitos necessários de Inteligência e se dê por minimamente atingido o objetivo de criação desta máquina.

Pode-se talvez separar os conceitos de dois tipos de inteligência: um natural, emergente, biológico, existente no homem - e, conforme a aceção, nos animais [HOF 86]. O outro artificial, construído, “não biodegradável”, “tecnológico”, por assim dizer. Entretanto a aceção de inteligência que aqui mais interessa é a ‘tecnológica’, implementável em um

sistema criado pelo homem, em contraposição à “biológica”. Esta serve de modelo a ser imitado: os pesquisadores de IA trabalham para inseri-lo ou fazê-lo nascer nas máquinas. Se os maravilhosos sonhos dos pesquisadores mais otimistas de IA se realizarem algum dia, então esta ‘inteligência tecnológica’ será a própria ‘inteligência natural’.

Olhando a história, não seria errado concluir que os feitos em IA anteriores a 1950 foram de fato preparatórios à verdadeira erupção de idéias e pesquisas que se seguiram, já então contando com a inestimável ajuda do computador, como ferramenta de modelagem. Por exemplo, concomitantemente aos trabalhos de pesquisa e construção dos primeiros computadores, o grande cientista britânico da área de informática - Alan M. Turing - assentava alguns pilares do que viria a ser o embasamento da IA [TUR 50]. Turing mostrou que os computadores do tipo digital, contrariamente aos analógicos, são máquinas universais, isto é, podem resolver qualquer processo formalizável em uma série de instruções de manipulação de elementos discretos. Até mesmo um computador analógico pode ser simulado razoavelmente por um digital (lembrando que o fato do primeiro trabalhar em sistema contínuo e outro em sistema discreto!) . Além de se preocupar em entender a essência e a capacidade destas máquinas, ele se enveredou por área até então adstrita aos filósofos: a essência da razão. Então escreveu este importante artigo [TUR 50], em que aponta “o interesse atual em ‘máquinas pensantes’ foi levantado por um tipo particular de máquina, usualmente chamada ‘computador eletrônico’ ou ‘computador digital’. Conclui então com a pergunta: *“Podem estas máquinas pensar”?*”

A indagação de Turing scandalizou e ainda choca muitas pessoas. De fato, Roger Shank [SHA 84] disse: “as pessoas acreditam que dizer que algo não humano é inteligente diminui a visão que os humanos têm de si mesmos como centro do universo. Golfinhos são inteligentes. Baleias são inteligentes. Macacos são inteligentes. Até cachorros e gatos são inteligentes”.

Apesar das inúmeras definições existentes de IA, o que demonstra o pouco conhecimento disponível sobre o tema, a acepção a que este trabalho se refere está mais bem retratada na frase: “a IA é o estudo das faculdades mentais com o uso de modelos computacionais” de Eugene Charniak e Drew McDermott [CHE 85]. Entretanto a possibilidade de implementá-la em outros tipos de máquina, que não os computadores, não deve ser negada liminarmente. Contornando os questionamentos filosóficos e semânticos, Turing propôs o teste a que chamou jogo de imitação, para decidir a questão:

“Ele é jogado com três pessoas, um homem (A), uma mulher (B) e um interrogador (C), de qualquer sexo. O interrogador fica em um quarto separado. O objetivo do jogo, para o interrogador, é determinar qual dos dois é o homem e qual a mulher. Ele os chama de X e Y e no fim do jogo ele diz ‘X é A e Y é B’ ou ‘X é B e Y é A’. O interrogador pode fazer perguntas a X e Y como: C: ‘Poderia X me dizer o comprimento dos seus cabelos?’

Agora suponha que X é realmente A e então deve responder.

A tem no jogo, por objetivo, tentar que C faça as identificações erradamente. Sua resposta poderia então ser: X: ‘Meu cabelo é curto e as minhas mechas mais longas têm aproximadamente 9 polegadas’. Para que o tom de voz não ajude o interrogador

as respostas podem ser escritas, ou ainda melhor, datilografadas (...).

O objetivo do jogo para B é ajudar o interrogador. A melhor estratégia para ele é provavelmente dar respostas verdadeiras. Agora fazemos as perguntas: ‘O que acontecerá quando uma máquina toma o lugar de A no jogo? Irá o interrogador decidir erradamente tantas vezes quantas ele o faria se o jogo fosse entre um homem e uma mulher?’ Estas perguntas substituem a original: “*Podem as máquinas pensar?*” [TUR 50].

2.3.2 Marcos históricos na IA

Mesmo antes do artigo em que Turing propôs seu célebre teste, muitos trabalhos já haviam sido feitos ou estavam em execução, e seguiram seu desenvolvimento, com muito bons frutos, como mostra o elenco dos principais eventos históricos citados neste texto.

Tanto J. Barreto [BAR 01] como G. Bittencourt [BIT 98] aceitam eventos similares para, didaticamente, definir épocas bastante bem demarcadas desta história.

2.3.3 Inteligência Artificial Conexionista - IAC - e Inteligência Artificial Simbólica - IAS

2.3.3.1 Introdução

A grande quantidade de conhecimento requerido na resolução de problemas como os de jogos ou mesmo de Sistemas Especialistas (SE) médicos e outros, representaram um considerável avanço, relativamente à época dos “problemas de brinquedo” [DRE 92] ou das aplicações em “micromundos” da IA inicial. As soluções atuais, devem enfrentar o crescimento combinatório do espaço de soluções, o que geralmente ocorre nos problemas do mundo real, o “macro-mundo”. Na década de 60, a pesquisa e a programação nestes “micromundos” mostrou que programas poderiam resolver problemas espaciais ou lógicos quando se confinava o assunto a ser trabalhado a pequenos ambientes: pequenos espaços de solução. No jargão técnico de IA, atualmente em voga, dir-se-ia que os espaços de solução eram submetidos a condições de contorno artificialmente simplificadoras. O sistema SHRLDU para gerenciar poucas formas geométricas ou o SIR, para construir frases simples em Inglês, são exemplos. NETtalk é um programa baseado em IAC para pronunciar um texto em Inglês, tarefa que, como nos sistemas baseados em regras, ainda não tem tido desempenho satisfatório [LUG 92]. A estes sistemas a literatura especializada tem cognominado “Toy Problems”, problemas de brinquedo. A experiência acumulada com os “Toy Problems” demonstrou que era possível resolver problemas através de métodos formalizados, automáticos, diferentes da forma ‘humana’, isto é, com intervenção de um ser com alguma racionalidade, única até então conhecida. Admitia-se que estes métodos tinham algum tipo de inteligência, alguma esperteza.

Para dar mais passos, procurou-se conhecer melhor o pensamento. Este fato é explicável, visto que na Física, Química, Matemática, Biologia e Ciências Naturais em geral, grande progresso tem sido feito, enquanto no conhecimento da mente em si mesma, pouco ou nada se tem avançado, além de sua emulação em alguns casos, como nos Sistemas

Especialistas. Na pesquisa sobre a inteligência, relativamente muito pouco se conseguiu. As ferramentas são inadequadas e ainda em construção. Por exemplo, para entender melhor o processo do andar ou do ficar de pé, equilibrado, temos as ferramentas das ciências citadas. Mas, mesmo com elas, apenas agora se conseguem robôs bem desajeitados, com pés enormes, etc. , diferentemente do ser humano, que se equilibra com eficiência sobre pés pequenos em relação à altura do seu corpo.

Já em 1950 A. Turing [TUR 50] previu que “no final do século se poderia falar em ‘pensamento mecânico’ sem perigo de contradita”. Minsky em 67 dizia que em uma geração “o problema de criar ‘inteligência artificial’ estaria substancialmente resolvido [MIN 67]. H. Simon, ainda em 1957, também vaticinava que em dez anos o computador seria campeão de xadrez, descobriria e provaria importante teorema matemático e as teorias psicológicas teriam a forma de programas computacionais [SIM 58]. Estas previsões se mostraram muito otimistas e, apesar dos esforços empreendidos, muitas soluções ficaram em nível de “micromundo”. Mas os Sistemas Especialistas têm dado resultados tecnológicos importantes em algumas áreas, melhorando as condições de vida do ser humano.

Em algumas direções o avanço tem sido mais lento. Na importante pesquisa da busca da Linguagem Natural, apesar de notáveis progressos, tradutores mecânicos e pouco confiáveis foram conseguidos. De fato, ainda no princípio da década de 60, comentando seu programa “The Logic Theorist” [NEW 63], Newell, Shaw e Simon diziam que o sistema “foi planejado para aprender como é possível resolver problemas difíceis tais como provar teoremas matemáticos, descobrir leis científicas a partir de dados, jogar xadrez ou entender o significado de prosa em Inglês”. Resta ainda muito trabalho para que se possa construir máquinas que de fato entendam o linguajar humano natural - e deste resultado depende a construção, por exemplo, de robôs que obedeçam ordens orais. O estágio atual, apesar dos progressos, ainda não garante que se esteja livre de traduções como a antológica “A carne é fraca mas o espírito é forte”⁷, que, vertida para o Russo e novamente para o Inglês, produziu: “A vodka é forte mas a carne está estragada”⁸. O livro [TVE 98] apresenta este fato como tendo ocorrido nos primórdios da pesquisa em Linguagem Natural, mas evidencia que o antigo ditado italiano “os tradutores são traidores”⁹ tem validade também para os software existentes. No caso dos tradutores *Português - Inglês* é comum se obter pérolas do tipo: “Como é bem sabido ...”, produzindo: “I eat is well known ...”.

Na IA, as primeiras abordagens, como a construção dos Sistemas Especialistas, procuravam emular o raciocínio, e se sedimentou na hoje intitulada Inteligência Artificial Simbólica - IAS - que se funda na hipótese de que a inteligência é consequência da manipulação formal de símbolos. Os projetos desta área dividem-se em dois grandes grupos: os com conhecimento baseado em regras e os baseados em casos. No primeiro grupo os sistemas construídos são conhecidos por uma série de denominações como: “Sistemas Baseados em Regras”, “Sistemas Baseados em Conhecimento”, “Sistemas de Produção”, “Sistemas de Inferência Dirigidos a Padrões” [TVE 98]. No segundo caso os sistemas são conhecidos

⁷“The spirit is willing, but the flesh is weak”.

⁸“The vodka is strong, but the meat is rotten”.

⁹“tradutori traditori”.

como de “Raciocínio Baseados em Casos” [BAR 01].

Outra linha - surgida nos anos 60 - procurou se inspirar na Biologia, observando como a Natureza tem agido para solucionar seus problemas. De forma geral se apoia na idéia de que, quando se duplicam as causas, também se duplicam os efeitos: fazendo-se um artefato igual ao cérebro ele também pensaria. Esta máquina não precisaria ser igual ou sequer parecida a um computador digital, mas esta ferramenta foi das mais adequadas, comparativamente às até então disponíveis, nas mãos dos pesquisadores. Logo esta linha se ramificou em duas direções principais:

- 1ª - *Redes Neurais*, que formou um conjunto de pesquisas, hoje englobado na chamada Inteligência Artificial Conexionista -IAC;
- 2ª- “*Linha*” *evolucionária*, que se inspira sobretudo no paradigma evolucionário de Darwin, para propor suas hipóteses. O conjunto abrangido pelos desenvolvimentos desta área é denominado Computação Evolucionária - CE, por alguns. Outros preferem designar a área de *Inteligência Artificial Evolucionária* - IAE [FRA 00], o que, mais uma vez, realça a necessidade de definições (Ver Capítulo 6).

A IAS se acelerou, sobretudo nos anos 70 e início dos 80, tendo alcançado grande distância em relação à IAC, pelo menos quanto à produção de sistemas, de trabalhos publicados e de atração de interesse geral de pesquisadores. Porém, apesar das grandes contribuições aportadas à Ciência da Computação e a outras, como financeira, saúde, tecnológica, etc. ficou claro que tem seus pontos fracos e mostra que ainda não é suficiente para explicar a inteligência humana. Talvez tenham razão os críticos desta concepção, ao negar que a inteligência seja apenas a *manipulação formal de símbolos*, como preconizam os adeptos da IAS.

Um conjunto de outros modelos, em alguns casos denominados genérica e conjuntamente de Processamento Paralelo Distribuído (“Parallel Distributed Processing: PDP”), estuda a forma como um comportamento inteligente pode emergir das interações de grande número de elementos pequenos e simples. Redes neurais são o exemplo mais conhecido de PDP, mas os Algoritmos Genéticos e outros paradigmas da Computação Evolucionária também modelam o aprendizado como um processo evolucionário em que atuam soluções candidatas, de forma competitiva. O modelo PDP também abrange autômatos celulares e outros, baseados no comportamento termodinâmico dos materiais, como o da “têmpera simulada” (“simulated annealing”)[MAZ 99]. O modelo PDP é cognominado subsimbólico, em contraponto ao modelo IAS, pois não usa símbolos para estudar a inteligência.

Em suma se pode dizer que na IA, a busca do ótimo em um espaço de soluções pode ser feita através de apenas *um elemento processador ‘inteligente’*, quando é conhecida como *IA tradicional ou monolítica* (Figura 2.2, extraída de [FRA 00]) e é o caso mais geral adotado nos SE. Na hipótese de haver *múltiplos elementos agindo paralelamente* diz-se que o modelo *IAD - Inteligência Artificial Distribuída é implementado*[LES 90]. Pode-se citar como exemplos desta concepção os diversos tipos de paradigmas de IAC e, em IAS, as arquiteturas de agentes autônomos [ROI 98] e as de quadro negro. Os modelos de

Computação Evolucionária também trabalham de forma semelhante, pois uma população de elementos que são soluções possíveis agem simultaneamente, competindo entre si, em busca da melhor solução. O título deste trabalho está embasado nesta acepção.

Como este trabalho tem seu foco na linha evolucionária, nos Capítulos 3 e 4 o tema será mais estendido, ficando-se aqui apenas com uma visão panorâmica de IAS e IAC.

2.3.3.2 Hipóteses de embasamento de IAS e de IAC

• A HIPÓTESE PSSH

A IAS se apóia na *Hipótese de Sistema de Símbolos Físicos* (“PSSH - Physical Symbol System Hypothesis”) [NEW 82], que admite: para criar inteligência a condição necessária e suficiente é que existam símbolos, estruturas de símbolos e regras que os manipulem. Os apóstolos do PSSH advogam, desta forma, que o cérebro humano e demais entidades que possuem inteligência, não fazem mais que manipular símbolos para gerar inteligência. Supõe também [TVE 98]:

1. No cérebro a manipulação é feita paralelamente;
2. A qualificação ‘física’ da hipótese deve-se ao fato de que ela presume que o cérebro tem estados físicos que correspondem ao tipo de estruturas usadas por um programa que processe símbolos;
3. Os defensores da PSSH não se preocupam com a forma pela qual a rede neural biológica trabalha - considerando-a de baixo nível, como fazem os usuários de linguagem de alto nível, que não se interessam pela arquitetura do computador que executará o programa que constroem - apesar de reconhecerem sua importância.

Alguns autores [LUG 92] classificam a PSSH de duas formas: forte e fraca. *Interpretação fraca da PSSH*: A hipótese é suficiente, isto é, a inteligência pode ser conseguida por qualquer sistema de símbolos físicos organizados apropriadamente. *Interpretação forte*: A hipótese é necessária, isto é, qualquer agente que exiba inteligência é sempre uma instância, um exemplar, de um sistema de símbolos físicos. Mesmo levando em consideração apenas a hipótese fraca, de suficiência, muitos resultados importantes têm sido conseguidos. A hipótese da necessidade é ainda questão aberta e existem grandes objeções como em [SEA 84], [WIN 73], [DRE 92].

Com enfoque oposto existe o PDP, afirmando que esta hipótese não é nem necessária nem suficiente [LUG 92] (p 693). R. Penrose [PEN 94] teoriza que para haver inteligência é necessário consciência e a mecânica quântica - que diz conter uma componente não algorítmica que a torna não executável em computadores digitais - é responsável pela consciência. Vários pesquisadores [TVE 98] têm propostas e argumentos quanto à aplicação da Mecânica Quântica no estudo do funcionamento do cérebro, que, entretanto, ainda estão nos seus primórdios, sendo pois pouco testadas.

Sintetizando, se se soubesse exatamente como as pessoas pensam, seria talvez fácil mostrar como uma máquina poderia ou não duplicar este processo. Há os que defendem ser o pensamento a manipulação formal de símbolos; outros dizem que é um processamento quântico e então um computador digital não poderia pensar, mas talvez um computador baseado na mecânica quântica pudesse. Por ora, alguns aceitam que, se uma máquina passa no teste de Turing, ela pensa; outros nem isso consideram válido.

• A HIPÓTESE CAUSA-EFEITO

A IAC supõe que seja válido seu axioma de base: “Se for construído um modelo suficientemente preciso do cérebro, este modelo apresentará comportamento inteligente. Se apenas uma parte do cérebro for reproduzida, a função exercida por esta parte emergirá do modelo” [BAR 01]. Sabe-se que no cérebro humano existem ao redor de 100 bilhões de neurônios, com aproximadamente mil conexões cada e cada neurônio “chaveia” ¹⁰ aproximadamente 100 vezes por segundo, o que daria $10^{11} \cdot 10^3 \cdot 10^2 = 10^{16}$ bits/segundo de velocidade de processamento; além disto, os neurônios não apenas recebem e enviam sinais mas também os processam localmente, o que torna o poder de trabalho cerebral ainda mais fantástico.

O exemplo mais antigo de computação neural é o modelo de neurônio de McCulloch - Pitts [MCC 43], que tem entradas excitatórias (+1) ou inibitórias (0) e saídas 1 ou 0, dependendo do resultado obtido no somatório ponderado das entradas atingir determinado limiar. O modelo é uma simplificação simbólica do trabalho supostamente exercido pelo neurônio biológico, recebendo informações, processando-as e devolvendo resultados. Estes autores mostraram que o modelo por eles proposto poderia formar agrupamentos para computar qualquer função lógica, fornecendo um sistema simulador computacional neural completo.

O aprendizado em computadores neurais baseou-se fortemente nos trabalhos de neurofisiologia e psicologia de D. O. Hebb [HEB 49]. Este cientista canadense lançou a teoria de que o aprendizado se dava no cérebro, via modificações das conexões sinápticas mais usadas, fortalecendo sua interação. Se um estímulo ativa certas sinapses, um estímulo semelhante, no futuro, tenderá excitar o mesmo caminho de sinapses através dessas células neuronais, provocando o aprendizado, isto é, o reconhecimento deste estímulo.

Nos idos anos 50, Frank Rosenblatt desenvolveu um algoritmo de aprendizado para um modelo de rede, a que chamou Perceptron, de apenas duas camadas de neurônios, uma de entrada e outra de saída [ROS 58]. O algoritmo implementava uma forma simples de aprendizado supervisionado e convergia para um conjunto de pesos, se tal conjunto existisse. Infelizmente, para certo tipo de padrões, mesmo se conhecendo a solução de convergência, não havia formas de fazer com que a rede convergisse para valores aceitáveis, como é o caso clássico da função XOR (ou-exclusivo). Neste exemplo,

¹⁰Metafóricamente, pois se sabe que têm funcionamento frequencial, portanto contínuo.

embora a função fosse representável por redes de mais camadas, o algoritmo de aprendizado só servia para redes de duas camadas. Foi assim demonstrado que redes de duas camadas não são computacionalmente completas. Pior que esta constatação, as razões deste comportamento eram desconhecidas [ROI 97].

2.3.3.3 Desenvolvimento da IAS versus Eclipsamento da IAC

Apesar de terem nascido praticamente gêmeas e convivido infância promissora, a IAS e a IAC tiveram evolução posterior muito diferentes. Os primeiros estudos em RNA: Redes Neurais Artificiais - expressão substituída por IAC neste trabalho - basearam-se no modelo de neurônio, proposto por F. Rosenblatt. No ano de 1969 no livro “Perceptrons” [MIN 88b] J. Minsky e S. Papert, usando conceitos topológicos e teoria de grupos, explicaram as restrições deste modelo primitivo de RNA e suas possibilidades computacionais. Esta comentada obra efriou o élan que a pesquisa em IAC prometia e, talvez, a morte prematura de F. Rosenblatt, logo após a publicação do livro de Minsky, sem que tenha tido tempo de responder as restrições por ele evocadas, esfriaram os ânimos e sobretudo os financiamentos em pesquisa de IAC [BAR 01]. O próprio Minsky, cuja tese de doutorado consistiu na construção da “máquina de aprender”, com conceitos de Redes Neurais, abandonou esta direção de trabalho e se bandeou para a IAS.

A volta do interesse nas RN se deu no início dos anos 80. O grupo de pesquisa de Rumelhart e McClelland em Processamento Paralelo e Distribuído propôs inovações importantes tanto na topologia - redes em múltiplas camadas - como na forma de aprendizado: a chamada metodologia da retropropagação. Este algoritmo de aprendizado, adequado a redes multicamadas, solucionou muitos dos problemas apontados e hoje muitos dos obstáculos iniciais foram ultrapassados. A pesquisa em IAC está novamente restaurada a nível de financiamento, tendo trazido importantes resultados em termos de novos modelos de neurônios artificiais, topologias de interligação e formas de estabelecer os pesos das interconexões, que levem a um aprendizado eficiente.

2.3.3.4 Algumas Comparações: IAS versus IAC

Em 1928 o matemático D. Hilbert lançou um conjunto de três conjecturas sobre a possibilidade da matemática - e mais amplamente de qualquer sistema lógico - ser completo e ao mesmo tempo consistente, isto é, conter todas as verdades matemáticas possíveis ao sistema e ao mesmo tempo não ter contradições. O princípio de Church-Turing [BIT 98] foi uma forma de responder às conjecturas de Hilbert, tendo sido construído de duas formas diferentes. Church, com o formalismo do “lambda cálculo” e Turing, com a “máquina de Cantor”, provaram que um sistema ou é completo ou consistente, mas não ambos simultaneamente.

No mesmo âmbito, E. Post [POS 43] criou o formalismo chamado “regras de produção”, base lógica em que assentam os SE. As abordagens dos três autores citados, para solução de problemas lógicos, se baseiam em enfoques totalmente diversos, para provar a mesma proposição. Ora, a IAS e a IAC são modelos diferentes de sistemas e podem ser con-

frontados com o princípio de Church-Turing pois são, na realidade, formalismos para solução de problemas, embora também dificilmente comparáveis, por serem oriundos de premissas totalmente diversas. Também se pode argüir que uma comparação em termos de performance entre o uso de sistemas IAC ou IAS não é fácil, porque há poucos sistemas desenvolvidos em ambos os paradigmas e também um deles pode ter sido mal desenvolvido e o outro com boa tecnologia.

Saito e Nakano [SAI 88] compararam um sistema de diagnóstico médico feito em Sistema Especialista simbólico e em rede, com treinamento de 300 casos envolvendo 23 sintomas possíveis para dores de cabeça; as redes acertaram 67% e o Sistema Especialista 70%. Tveter [TVE 98] relata exemplos de sistemas em IAC e IAS para prever explosões solares, ambos com precisão semelhante. O IAS exigiu o trabalho de 1 homem/ano, mais de 700 regras e 5 minutos de máquina para fazer uma previsão. O IAC foi feito com 1 homem/semana de trabalho e respondia em poucos milissegundos. O sistema MYCIN usa conhecimento médico especializado para diagnosticar meningite e infecções bacteriológicas do sangue e levou 20 homens/ano para ser desenvolvido, embora a construção posterior de "shell para Sistema Especialista" tenha feito com que o sistema PUFF, para diagnosticar problemas pulmonares, levasse 5 homens/ano. A Figura 2.3, extraída de [LUG 92], ilustra com alguns SE famosos a tendência descendente dos custos, em termos de homens/ano investidos no seu desenvolvimento.

É conhecido o fato que os sistemas IAS se diferenciam dos IAC também porque as conclusões tiradas pelos IAS podem ser checadas com as regras que as suportam. Pode-se dizer que os SE são abertos à inspeção, pois permitindo que se saiba o caminho percorrido pelo sistema para se chegar à conclusão, torna esta mais confiável e mais facilmente assimilável pelo homem. Isto geralmente não pode ser feito em um IAC, exceto no caso de ser disponível o conjunto de treinamento da rede, quando pode-se então comparar os resultados com os casos parecidos de treinamento [TVE 98]. Normalmente os processos tradicionais, que usam as técnicas numéricas, estatísticas, de pesquisa operacional, etc. devem ser os preferidos se podem solucionar adequadamente o problema, pois geralmente são de mais fácil aplicação e dão melhores resultados.

Os SE simbólicos não usam estes métodos e sim processos heurísticos, o que faz com que se pergunte qual o grau de acerto a ser exigido em suas soluções para que o sistema seja aceito. Uma variação do teste de Turing pode ser usada: O SE seria aceito ao atingir um nível de performance em que pessoas da área, em teste cego, não pudessem diferenciar entre as respostas advindas do SE e as dos melhores esforços dos especialistas. É fato que, quanto mais informações se põe em um sistema, mais lento ele fica, pois terá que procurar em um banco de conhecimento maior. A mente humana funciona de forma inversa, devido possivelmente ao modo intensivamente paralelo com que o cérebro processa as informações [HIL 85].

Por outro lado, parece quase impossível criar um conjunto de regras que digam a um sistema exatamente o que fazer, em cada circunstância. Este é um fato importante para o objetivo desta tese pois ilustra quão diferentes são os modelos que simulam a

inteligência, ou o que se sabe do seu funcionamento, sendo mais um exemplo que motiva a busca de processos mais biologicamente inspirados. Outros paradigmas de solução de problemas, como os citados no Capítulo 4, estão ajudando a minimizar a falta de flexibilidade inerente aos SE.

Hoje, mesmo SE já distribuídos em escala comercial, têm muitas limitações de qualidade e falta de generalidade em seus resultados, incluindo a proverbial ineficiência em exibir bom senso, bem como o de perceber que as coisas mudam, o ambiente varia com o tempo. Entretanto o nobelista H.A. Simon argumenta que muito da originalidade dos seres vivos se deve à riqueza do ambiente em que vivem, em vez da complexidade dos seus programas internos, que podem ser bem simples [SIM 81].

Em resumo, a IA tem dois problemas básicos, que, em termos gerais, são: representação do conhecimento e sua recuperação. O primeiro se relaciona com a captura em sistema formal, isto é, aceito pelo computador, de toda a gama de conhecimento necessário para que ele exiba comportamento inteligente. O segundo se refere à busca de respostas, de forma eficiente, em um espaço de soluções alternativas.

Muito do interesse em IAC advém do fato deste paradigma enfrentar algumas fraquezas da IAS, que tem diversos pontos sensíveis principais citados e ainda o declínio súbito do funcionamento, em lugar de queda suave, como na maioria dos sistemas naturais. Isto advém da lógica tudo ou nada em que se baseia grande parte dos sistemas de IAS, embora hoje também se utilize Lógica Fuzzy ¹¹, o que ameniza o problema. Ainda, dados incompletos ou com ruído são dificilmente tratados. O processamento largamente paralelo da IAC baseia-se em grande número de elementos computacionais simples e não no modelo de computador de von Neumann, que separa nitidamente dados e processo. Também não existem nele símbolos e regras, como na IAS, para representar o conhecimento, sendo este captado na forma de padrões de interações entre os componentes, os neurônios. Os modelos PDP são *treinados* a trabalhar estes padrões e as máquinas de von Neumann são *programadas*.

2.4 ESTUDO DE UMA METODOLOGIA PARA MENSURAÇÃO DA IA: UM QI PARA MÁQUINAS?

2.4.1 Ponderações iniciais

Uma área onde a pesquisa científica moderna tem alocado grandes recursos é a da criação de máquinas inteligentes, tarefa de grande importância científica. Atingida esta meta, o objetivo de materializar a Inteligência Artificial - IA - teria sido então alcançado.

Por ora, como não se sabe ao certo nem o que seja a inteligência “natural”, isto é, a não fabricada, tem-se como objetivo da IA “o estudo das faculdades mentais com o uso de modelos computacionais” [CHE 85]. Portanto, inicialmente investe-se na criação de modelos do que se imagina ser a inteligência e então se procura usar estes modelos em

¹¹Lógica Nebulosa.

sistemas computacionais, para a resolução de problemas.

O esforço para ver como o pensamento funciona, com o objetivo de resolver problemas de IA, tem-se mostrado promissor devido às inúmeras respostas já obtidas pela tecnologia, espelhando-se nas soluções encontradas pela Natureza em problemas semelhantes. Na verdade, a IA tem sido tratada às vezes como a pedra filosofal da Ciência da computação, sendo uma esperança para a solução de problemas ainda intratáveis com as técnicas conhecidas de programação algorítmica.

Até esta seção se procurou tratar os conceitos hoje mais largamente aceitos pela comunidade pesquisadora da área de IA e se deixou claro que existem três vertentes principais, com pressupostos básicos diferentes, procurando se aproximar desta meta. Como será visto no Capítulo 4 a IAS, com enfoque de busca de leis gerais e símbolos, adota o sistema “top-down” e se apoia na Hipótese do Sistema de Símbolos Físicos [NEW 82]. Para alguns extremistas desta abordagem, símbolos e regras são necessários e suficientes para os sistemas inteligentes.

De modo antagônico, a IAC propõe que a inteligência emerge da interação massiva e simultânea entre elementos processadores simples, chamados neurônios, no enfoque “bottom-up” (ver 4.1), tendo por embasamento a hipótese da modelagem do cérebro, total ou parcialmente [BAR 01]. Nesta direção tem sido desenvolvida grande área de estudo que inclui, de modo preponderante, as Redes Neurais Artificiais.

A terceira vertente, a IAE, não contempla o tratamento, pode-se dizer, um tanto quanto ‘mecanicista’ das outras duas e propõe em alternativa sua “versão evolucionária”: a inteligência seria fruto de um processo histórico de crescimento. O alicerce deste método é a teoria evolucionista de Darwin [DAR 59], que embora não provada matematicamente - de resto as hipóteses que sustentam as outras duas vertentes também não o foram - tem dado bons frutos às áreas onde foi empregada.

Deve-se dizer que há ferrenhos defensores de cada uma das três vertentes IAS, IAC e IAE como sendo a que definitivamente detém a verdade. O que parece mais promissor, no estágio atual das pesquisas, é que a constatação factual tenha traços de cada uma delas em maior ou menor proporção e pode inclusive ser de outra natureza, com a qual os pesquisadores não tiveram ainda a ventura de se defrontar.

Entretanto, qualquer que seja a explicação correta deste conceito, a existência de medidas de importância, de uma quantificação, com a qual se pudesse construir hipóteses mais promissoras, elaborar teses e antíteses sobre elas e talvez se chegar a sínteses úteis, seria de todo relevante. Parece que chegou o tempo de se começar a pensar (e agir) em estabelecer um padrão de comparação que pudesse objetivamente informar quão longe se andou na caminhada para construir sistemas de IA melhores. Imaginar um Quociente de Inteligência - QI - para máquinas seria provavelmente um avanço, mas infelizmente a história do desenvolvimento de técnicas para utilizar um QI “humano”, a primeira fonte a ser verificada para se produzir algo semelhante em IA, aponta para zona muito nebulosa. Portanto, algumas conjecturas são apresentadas, admitindo-se previamente tal possibilidade hipotética. Aliás, deve-se lembrar o sentimento corrente entre os pesquisadores, sobretudo

os de áreas exatas e tecnológicas, que um conhecimento só está de fato sedimentado, quando puder ser *formalizado* de algum modo. Em última análise, quando for exprimível por um número ¹².

Em Ciência da Computação há uma área na disciplina de Engenharia de Software, chamada *métrica*, que visa o desenvolvimento de metodologias dedicadas a quantizar características como eficiência e confiabilidade de sistemas de software. Ela ainda não tem o mesmo desenvolvimento que os métodos quantitativos desenvolvidos pelos sistemas de engenharia Mecânica ou Elétrica, por exemplo, que se baseiam nas leis físicas para dizer, por exemplo, que um motor elétrico tem 95% de eficiência, pois só 5% da energia elétrica que consome não é transformada em energia mecânica, disponível no seu eixo. Não dispondo destas leis fundamentais, a “Engenharia de Software continua a procurar as suas próprias raízes” ([GLE 00]), que a sustentem e alimentem.

Estuda-se aqui uma proposta protótipo para uma métrica, um QI para comparar os “níveis de inteligência” das “máquinas inteligentes” assim concebidas. Tal pesquisa traria um método para se materializar em um número confiável, o nível de melhoria conseguido, se for o caso, com a mudança introduzida. As dificuldades, como se verá em seguida, são semelhantes às enfrentadas pela obtenção de métricas em Engenharia de Software. Como se verificou anteriormente, sistemas de IA também buscam “suas próprias raízes”. Enquanto os pesquisadores não se defrontarem com as leis fundamentais da inteligência, se é que elas existem, os desenvolvimentos feitos na busca da medição de suas características são simples simulações, mas que podem contribuir com alguma luz.

As primeiras contribuições práticas para esta pesquisa foram dadas por Turing [TUR 50]. Este, preliminarmente, bem colocou que o problema de construção de “máquinas inteligentes”, passa inicialmente pela definição de qual “máquina” se fala - tendo ele assumido como o computador digital - e simultaneamente, de “inteligência”. Para este conceito Turing, em vez de definir, propôs um modelo, uma comparação entre uma máquina supostamente inteligente e um ser axiomáticamente admitido como inteligente, definindo o seu famoso “teste”.

Turing contornou assim uma parte do problema, supôs a máquina já construída, mas para atingir a meta de fazer máquinas emularem a inteligência, os primeiros esforços foram no sentido de compreender a própria inteligência. Aliás este problema já intriga a humanidade há mais de dois milênios: na antiga Grécia Aristóteles definiu o homem como “ser racional”, deixando em aberto, como ainda está hoje, o problema do entendimento do que seja a qualidade ‘racional’ e criando o conhecido e ainda insolúvel problema mente-corpo, que vem ocupando algumas das melhores cabeças científicas. De fato, John Searle diz que “muitos filósofos pensam e consideram como o mais difícil de todos os problemas a relação de nossas mentes com o resto do universo ... que na sua versão contemporânea assume habitualmente a forma: como é que nossa mente se relaciona com o cérebro?” [SEA 84].

¹²“O livro da Natureza é escrito em símbolos matemáticos” (Galileu).

2.4.2 Alguns enfoques considerados na medição da Inteligência

Inúmeras formas explicativas foram propostas para o problema mente-corpo e, olhando-as sob o ponto de vista filosófico, pode-se englobá-las nas duas correntes gerais principais, chamadas monismo e dualismo. No monismo há os que dizem ser o universo apenas espírito e a matéria é dele advinda, os chamados idealistas. Os materialistas dizem o contrário: há apenas matéria e a mente emerge das interações da matéria [SEA 84], [ARA 93]. Vê-se então que não está decidida nem a verdadeira constituição básica do homem.

“Esquecendo” este problema fundamental mas mantendo o fito de aclarar o entendimento do que seja a inteligência, várias abordagens foram efetivadas e algumas se preocuparam em medir, através de testes mentais, habilidades que supostamente possam ser mensuráveis pelos mesmos, o que não é unanimidade entre os cientistas envolvidos. Entre os vários ângulos de estudo da inteligência, cita-se alguns, mais em destaque na ciência atual:

1. A Psicologia criou um ramo específico, mais preocupado com os aspectos de mensuração, e denominou-o Psicometria.
2. Há também a Psicologia Cognitiva, que enveredou pelo caminho do estudo dos processos de funcionamento, com os quais a mente hipoteticamente trabalha.
3. Um terceiro paradigma usa a Psicologia Cognitiva e complementa-a com o meio ambiente em que a inteligência interage, fazendo um estudo contextualizado.
4. Os esforços de uma quarta concepção são direcionados para os aspectos biológicos e seus seguidores são chamados reducionistas, pois acreditam que uma explicação - não uma mera descrição - da inteligência só é possível se for baseada nos substratos biológicos, notadamente os neurais, dos quais hipoteticamente ela emana.

Todos estes aspectos têm sido influenciados pelas concepções filosóficas monista e dualista.

O psicólogo britânico Charles E. Spearman [LAU 01], um dos precursores do enfoque psicométrico, sugeriu a Teoria da Inteligência Geral, onde qualquer atividade que requeira inteligência exige a aplicação do *fator de inteligência geral g*, que influi em todas as tarefas que demandam inteligência. Desenvolveu um novo método estatístico, hoje definido como Teoria da Análise Fatorial, para pesquisar o hipotético fator comum, presente nas variações de performance encontradas entre os indivíduos exercendo diferentes atividades intelectuais. Através destes testes estatísticos, em que também K. Pearson trabalhou, encontrou-se correlações fortes entre grupos de variáveis, por exemplo as coletadas com testes em músicos e matemáticos clássicos, da França e da Inglaterra, o que indicava a possível existência de um fator geral subjacente, responsável por esta ausência ou presença de correlação.

Deste outro modo, a pesquisa da inteligência também frutificou, com o aparecimento da citada teoria [JOH 98] que hoje é importante instrumento ao dispor dos cientistas.

Estes fatores da inteligência permanecem como objeto de especulação, tanto o geral, quanto um hipotético segundo fator, desta vez específico, típico de cada atividade.

Em 1971 o psicólogo americano Raymond B. Catell [LAU 01] propôs uma síntese entre a proposta “monofatorial”, de Spearman e a “multifatorial”, de Louis L. Thurstone [LAU 01] e produziu outra teoria em que a habilidade geral *g* era dividida em outras duas: a fluida - habilidade para dedução e indução - e a cristalizada, própria de conhecimentos específicos. Destas J. P. Guilford ([GUI 71]) listou 120 possíveis e, pasme-se, mais 30 posteriormente.

Além destes, Robert J. Sternberg [STE 97] oferece o seu “modelo triárquico”, com a inteligência social, a emocional e a prática.

Os psicólogos cognitivos, em lugar de estudar testes, foram à procura dos processos mentais que, a seu ver, embasam a inteligência e fundaram sua teoria na hipótese de que ela é composta de um conjunto de representações mentais de informação, isto é, símbolos, e de um conjunto de regras que definem o trabalho com estes símbolos. Uma corrente de seguidores desta teoria optou pela construção de sistemas computacionais de inteligência cognitiva, isto é, para eles o cérebro pode ser modelado pelo computador. Desta corrente, os psicólogos americanos Allen Newell e Herbert A Simon [NEW 82] centram seus trabalhos na idéia de que os processos cognitivos são bem estruturados e de processamento serial, simuláveis pelos computadores digitais seriais baseados na máquina de von Neumann. Jay C. McClelland e David E. Rumelhart [RUM 86a] propuseram modelos de mente baseados em “processamento paralelo e distribuído”.

As Teorias Cognitivas Contextuais tratam da forma como os processos cognitivos operam nos vários ambientes em que se aplicam. Howard Gardner [GAR 94] conjectura que não existe uma inteligência única, mas no mínimo sete, isoladas, independentes. Robert J. Sternberg [STE 97] sustenta que existe uma única inteligência, mas composta de três aspectos integrados e interdependentes: os processos cognitivos e suas representações, a aplicação destes processos ao meio ambiente e a integração experimental relacionando os mundos interno e externo [ZEI 87]. As correntes atuais tendem a conceber a inteligência como produto de interações entre o indivíduo e o ambiente, isto é, há nela traços adquiridos e outros advindos do meio sócio-cultural, sendo objeto de pesquisa quais seriam os componentes de cada um e como se integram [FOU 01].

As luzes trazidas pelas Teorias Biológicas para as bases da Inteligência são tênues, apesar dos avanços conseguidos principalmente em estudos relacionados a três campos:

1. Faz-se pesquisas procurando relacionar cada aspecto da inteligência com a região do cérebro que supostamente o gera. “Em pormenores ninguém sabe, mas temos boas provas de que certas regiões do cérebro são especializadas para certos tipos de experiências” [SEA 84]. Por exemplo, a habilidade lingüística é situada principalmente no lobo temporal do cérebro. Esta divisão modular é bastante aceita no meio acadêmico, mas há outras, como a holística, que defende uma distribuição mais ampla [CHU 88].
2. Também há estudos promissores procurando relações entre as ondas eletromagnéticas

oriundas da atividade elétrica cerebral, medida através do eletroencefalograma, e as atividades mentais.

3. Busca da possível relação entre estas atividades e os fenômenos do fluxo sanguíneo observado nos tecidos cerebrais formam outra vertente de investigações.

Estas linhas ajudam a entrever em que medida a genética é responsável pela formação da inteligência e em que medida o é o meio ambiente, a educação, a criação, a cultura, a sociedade, etc.

Para o objetivo da mensuração do QI de máquinas, parece que os quatro enfoques existentes de estudo da inteligência não são de grande ajuda, pois deixam claro que em termos de definições científicas, a Inteligência ainda é terreno de especulação.

2.4.3 “História” do QI ‘humano’

Os psicólogos franceses Alfred Binet e seu colaborador Theodore Simon, em 1905 propuseram a primeira escala de desenvolvimento intelectual, com o objetivo de medir “a bela inteligência pura” isto é, sem interveniência de outros fatores [HUI 64]. Surgiu em um trabalho a que foram incumbidos pelo governo francês, com a finalidade de estudar formas que assegurassem educação adequada às crianças mentalmente retardadas.

Binet observou que elas resolvem problemas de maneira análoga a crianças “normais”, mais jovens e testou a idéia de que o nível intelectual pode ser relacionado à idade. Fizeram listas de questões empiricamente destinadas a cada idade e abandonaram as questões respondidas erradamente por mais que 25% das crianças. Assim se construiu um conjunto de perguntas adaptadas à idade da criança, construído supostamente de modo a espelhar o conhecimento médio que hipoteticamente seria dominado pelas crianças. Se uma criança responde bem as questões de 8 anos e falha nas de 9, ela teria 8 anos de idade mental. À razão entre esta idade, dividida pela idade real foi, mais tarde, dado o nome de *Quociente de Inteligência - QI* [LAU 01]:

$$QI = 100 \frac{Idade\ mental}{Idade\ cronológica}$$

A experiência mostrou que o QI tem distribuição estatística muito próxima à normal. Por construção, o QI médio é de 100 e também se constatou que dois terços das pessoas - ditas normais - ficam entre $QI = 85$ e $QI = 115$. Infelizmente logo etiquetou-se as pessoas como mentalmente dotadas ($QI \geq 130$), débeis mentais ($QI < 70$), idiotas ($QI < 50$) e imbecis ($QI < 20$), taxando-as de “normais”, “gênios” e assim por diante, com base apenas na fraca evidência fornecida pelos escores de QI.

Hoje as faixas abaixo da normalidade passaram a ser denominadas de moderadamente, severamente ou profundamente retardados mentalmente e se admite que os indivíduos nestas condições podem ser, respectivamente, educados, treinados ou devem ser custodiados. Na atualidade, quando estes testes são usados, poucas vezes eles continuam envolvendo idade mental, adotando-se em seu lugar a acepção do percentual de pessoas de um

grupo que teria tal medida de QI. Com este entendimento, nos EUA, por exemplo, existem inúmeras sociedades cujos membros são admitidos com testes que supostamente só seriam resolvidos por um determinado percentual das pessoas.

O índice do QI foi inicialmente adotado com entusiasmo por diversas correntes psicológicas, mas logo vozes reticentes, ou liminarmente discordantes, apareceram, apontando que ele depende fortemente da educação recebida pelo indivíduo, do seu meio ambiente social e familiar, etc. Este índice, no máximo, indicaria uma performance instantânea e não uma história evolutiva ao longo de um período ou a capacidade futura do indivíduo, sendo então de utilidade muito limitada. Sendo obtidas em condições artificiais, em ambiente estranho ao habitual, as respostas indicariam tanto o conhecimento já adquirido em função do ambiente a que ele esteve sujeito, quanto a “bela inteligência pura” propriamente dita, a que Binet se referiu, isto é, à capacidade de adquirir conhecimento.

O eminente psicólogo russo Lev S. Vygotsky (1896 - 1934) [VYG 87], se-para o desenvolvimento real, aquele correspondente às habilidades dominadas pelo indivíduo e mensurável por provas adequadas, do desenvolvimento potencial, correspondente às habilidades em estado latente, passíveis de desenvolvimento via aprendizagem. Cria também o conceito de “Zona de desenvolvimento proximal”, definido como a distância que separa os dois estágios de desenvolvimento. Este psicólogo russo, com seus principais colaboradores Luria e Leontiev, sugeriu aos partidários das visões então existentes de ciência natural, contrários aos da visão de ciência mental, a nova alternativa Sócio-Histórica, para a Psicologia. Para Vygotsky os processos psicológicos se modificam qualitativamente ao longo do tempo, e daí sua conotação “histórica”. O QI definido por Binet, seria no máximo como uma tomada fotográfica instantânea do desenvolvimento real. Frise-se que este instantâneo seria imperfeito, pois estaria necessariamente “viesado” pelos aspectos culturais e sociais do meio ambiente em que o indivíduo estaria imerso.

Apesar de existir escola que defende ser a inteligência hereditária [MUR 94], inata e, em oposição, a psicologia “behaviorista” que diz ser adquirida, as correntes atuais tendem a concebê-la como produto da interação entre o indivíduo e o ambiente, isto é, há nela traços adquiridos e outros advindos do meio sócio cultural. Quais os componentes de cada um? como interagem? são questões objeto de pesquisa [HUT 99].

A tarefa de medição da IA promete valor agregado relevante pois ensinaria instrumento comparativo muito importante entre sistemas inteligentes, tanto de hardware quanto de software. A criação de um índice que desse uma gradação da Inteligência de um sistema, permitiria decidir que sistemas são mais adequados, mais eficientes e baratos e a própria pesquisa de tal índice propiciaria possivelmente novas idéias e direcionamento de trabalhos na área de IA e outras. Mas, pelos antecedentes colocados, vê-se que não é uma empreitada trivial. De fato, a “Inteligência natural” parece ser uma adaptação da Natureza, uma habilidade que evoluiu ao longo das eras biológicas e que aparentemente produziu seu melhor exemplar na Inteligência humana [MIT 00]. Com as dificuldades já apontadas na discussão do “QI humano”, falar em QI para máquinas, configura-se como tarefa inglória, abordável apenas em “lato sensu”, mesmo porque ainda é controverso a atribuição de Inteligência a

máquinas.

A medida da IA só faz sentido, à primeira vista, se ela for definida em termos de fenômenos físicos naturais, mensuráveis, pois a ciência ainda não tem um conjunto de ferramentas ou processos para atacar o mundo imaterial. Parece que esta mensuração só se efetivará se a hipótese do mundo ser de constituição monista e materialista for comprovada. Então o instrumental científico atualmente disponível, ou a ser desenvolvido, seria aplicável e poderia funcionar, eventualmente.

Entretanto, mesmo entre os puramente materialistas, novas formas de encarar os fenômenos mentais têm sido propostas, como as baseadas na moderna Física Quântica [TVE 98].

A proposta de mensuração da IA tem que ser precedida da condição da definição do “quê se vai medir”, para depois estabelecer “como medir”. Da discussão anterior sobre os testes de QI e das várias concepções existentes sobre a “Inteligência natural, biológica”, fica evidente que ainda não está disponível uma definição de Inteligência e, segundo alguns, jamais estará, por ser Inteligência um conceito aberto, não exato [CAL 94]. No mundo da Física, a Teoria Newtoniana foi completada pela Teoria da Relatividade, que por sua vez foi ampliada pela Teoria Quântica, mas a busca de uma “Teoria de Tudo”, apesar dos grandes e seculares esforços, ainda não teve sucesso. Assim também uma teoria geral, uma explicação absoluta da Inteligência não está até agora disponível, talvez porque a mesma não exista ou porque ainda o local correto não foi explorado.

É possível esta mensuração? Negar é problemático, visto não termos conhecimentos suficientes sobre o tema. Além disto, uma comprovação formal, clássica, é de difícil construção.

Para avançar no problema, admita-se a possibilidade de medição da IA. Tenha-se à vista as dificuldades trazidas pelo fato de ser problema de múltiplas facetas, como:

1. O próprio objeto a ser mensurado não é ainda definido;
2. O fato de não se conhecer todas as componentes de uma eventual Inteligência e nem se existem várias Inteligências;
3. A constatação de que a Inteligência não é só uma ‘virtude’ estática de quem a possui mas sim, provavelmente de um processo que se passa entre o sujeito e o meio em que ele atua.

Em razão disto, a função que fizesse a medição deveria levar em consideração esta “dependência” indivíduo-ambiente.

2.4.4 Considerações algébricas

O conjunto QI destas medidas só seria de interesse científico e prático se seus elementos pudessem, de alguma forma, ser comparados para se averiguar se são iguais, diferentes, maiores ou menores entre si. Apesar destas condições parecerem por demais triviais,

deve-se lembrar que sistemas hoje tidos como inteligentes, resolvendo um mesmo problema, mas usando diferentes enfoques de IA, não podem ser comparados quanto aos operadores algébricos $>$, $<$, $=$ ou \neq . Este fato é referenciado em [TAN 95] e em [TVE 98]. Parece que alcança as máquinas a “maldição do QI” construído para os humanos: como não se sabe bem o que medir, perdem o sentido os aspectos práticos do como medir, com que medir, onde, quando, etc.

Um problema genérico pode ser modelado como a interação de três conjuntos: I , T e O , onde I identifica os elementos de entrada, O os de saída e T uma transformação que possibilite a obtenção de O a partir de I . No caso da medição do QI de ‘máquinas’ inteligentes, estas seriam o conjunto I . As medições dos QI formariam O e T seria a metodologia de medição: o mapeamento $I \rightarrow O$. Como até aqui colocado, tem-se grandes problemas na definição de máquinas inteligentes, talvez ainda maiores na do QI adequado e portanto o encontro de T não deve ser tarefa simples. Está-se à procura de uma função que gere o QI tendo por domínio o conjunto de ‘máquinas inteligentes’. A saída da função seria um elemento de um conjunto QI que tenha a propriedade da relação de ordem.

Deve-se atentar que o conjunto I , da função de medição, pode produzir valores entre os quais não haja possibilidade de estabelecer distâncias euclidianas, uma vez que resultaram de diferentes considerações de “fatores de inteligência”, com pesos heterogêneos, significados advindos de diversos ambientes de coleta, etc.

Construir uma função de QI entre o domínio - isto é, o conjunto das máquinas inteligentes I - e o contra-domínio - o conjunto O das medições obtidas - pode ser possível, mas o problema principal é que cada elemento do conjunto domínio só terá sentido se puder ser referenciado, se pertencer a um indivíduo inteligente bem determinado. Mas este indivíduo será mais ou menos inteligente dependendo do meio em que estiver inserido, de fatores evolucionários a que foi submetido, além de outros. É um problema multifacetado pois a Inteligência não é só do ‘dono’, mas existe em dependência com o meio ambiente, isto é, cada componente da Inteligência de um indivíduo ou de uma máquina, deverá ser valorada em função do ambiente em que o mesmo atua. Assim, em termos absolutos, dissociado de um ‘habitat’ específico, parece impraticável definir QI’s para máquinas.

No atual estágio da pesquisa em inteligência, definir uma *relação de ordem completa* [MON 71] para o conjunto O das medidas de inteligência das máquinas, seria admitir que todas as máquinas estariam trabalhando com um determinado enfoque de IA e a medição seria consequência da aplicação *daquele enfoque*. Poder-se-ia talvez ter uma relação de ordem completa para aquele enfoque, mas não para todos os conjuntos O das máquinas inteligentes construídas com outros enfoques, já que a “materialização” da inteligência em um enfoque não seria idêntica à de outro enfoque, mesmo no caso particular em que o problema resolvido fosse único.

À vista das dificuldades trazidas pelo fato de ser problema multifacetado, de não se conhecer todas as componentes de uma eventual inteligência e nem se existem várias inteligências, talvez uma possibilidade fosse a de desenvolver vários instrumentos - vários metros - assim como várias metodologias para aplicar estes instrumentos aos diferentes

paradigmas de IA disponíveis.

Os conjuntos munidos da propriedade de *ordem total* ou relação de *ordem completa* têm interesse especial devido às possibilidades de comparação de grandeza entre seus elementos construtivos. A seguir a definição formal desta propriedade:

Dados os conjuntos genéricos E e F , qualquer subconjunto do produto cartesiano $E \times F$ é definido como uma relação R . Se $F = E$, então se diz que R é uma *relação em E*.

No caso de existir um conjunto I de máquinas inteligentes e estas inteligências admitirem mensuração, ter-se-ia o conjunto O das medidas obtidas. O gozaria da *relação de ordem completa* se seus elementos obedecessem os axiomas:

- 01.- Propriedade reflexiva: $\forall i \in O, \quad iRi$
- 02.- Propriedade anti-simétrica: $\forall i, j \in O, \quad \text{se } iRj \text{ e } jRi, \quad \text{então } i = j$
- 03.- Propriedade transitiva: $\forall i, j, k \in O, \quad \text{se } iRj \text{ e } jRk, \quad \text{então } iRk$
- 04.- Propriedade de universalidade: $\forall i, j \in O, \quad iRj \text{ ou } jRi$

Um caso de interesse especial é o de R ser a relação de ordem habitual, geralmente simbolizado por \leq , quando obedecerá os quatro axiomas enunciados acima e se diz que R é de *relação de ordem completa* ou que o conjunto O é de “ordem completa”. Na hipótese de que apenas os três primeiros axiomas serem obedecidos, se diz que R é de *ordem parcial*, pois nem todos os elementos de O poderão ser comparados em R . Seria muito interessante se o conjunto O existisse, pudesse ser obtido e tivesse a propriedade de *relação de ordem completa*!

Se a inteligência for representada por uma ênupla composta pelos diversos aspectos que a caracterizam, o conceito de ordem parcial se mostra mais viável, referindo-se então a um dos componentes da ênupla.

2.4.5 Propostas de métricas

- Um QI para “máquinas inteligentes simbólicas”

As implementações mais comuns do paradigma IAS são os Sistemas Especialistas construídos com base nas regras de produção de Post [POS 43]. Se um destes sistemas tiver n regras, e x delas não são necessárias por serem redundantes ou não aportarem conhecimento útil ao sistema, então, sem rigorismo matemático, se poderia dizer que somente $(n - x)$ regras seriam “linearmente independentes” [FAL 01b]. Poder-se-ia admitir que x regras não cooperam com nenhum grau adicional de inteligência ao sistema. Consequentemente o quociente

$$QI_S = 100 \frac{n - x}{n}$$

poderia ser uma medida da inteligência do sistema, em relação a este enfoque. Seja um

exemplo de medida do QI de um sistema que examina árvores genealógicas ou mesmo relações de parentesco entre pessoas e supondo que se construiu o conjunto de regras de Post em Linguagem PROLOG, incluindo as cinco linhas abaixo:

- i) pai (josé, jacó);
- ii) avô (josé, isaac);
- iii) pai (jacó, isaac);
- iv) avô (jacó, abraão);
- v) pai (isaac, abraão);

As regras (ii) e (iv), por exemplo, não carregam informação adicional ao sistema, pois “jacó é pai de josé” e “isaac é pai de jacó” têm como consequência lógica, nos casos padrões: “isaac é avô de josé”. Então as regras (ii) e (iv) poderiam ser eliminadas do sistema, não lhe trazem inteligência, são linearmente dependentes de outras nele já inseridas.

Deve-se evidenciar ainda uma vez que este é um *estudo*, uma *proposta inicial* a ser trabalhada. Com esta formulação do QI_S , duas máquinas bem otimizadas quanto ao conjunto de regras poderiam resultar no mesmo QI_S , o que limitaria sua utilidade. Uma análise mais detalhada pode mostrar que a inserção balanceada de fatores como “tempo médio de resposta”, “*custo* computacional”, “facilidade de incorporação de novos conhecimentos”, etc. incrementam a abrangência do índice.

- Um QI para “máquinas inteligentes connexionistas”

Admita-se que uma rede neural resolva um problema com n neurônios, quando adotando-se outra topologia, outro tipo de neurônios (dinâmicos, por exemplo), etc. bastassem $n - x$, sendo portanto x deles não utilizados. O índice de inteligência desta rede - QI_C - poderia ser definido da mesma forma que QI_S .

$$QI_C = 100 \frac{n - x}{n}$$

É imediato que a união dos conjuntos das medidas QI_S de e QI_C não formariam um novo conjunto munido de ordem completa, visto que entre as regras dos SE e os neurônios das redes neurais não se encontrou um elo numérico de avaliação mútua possível.

Repisando o dito acima para o QI_S , esta sugestão de QI_C se atém ao *número de neurônios* empregados, devendo-se verificar a plausibilidade de inclusão de outros fatores que complementassem o índice com a “qualidade” das soluções apresentadas, como por exemplo os relativos ao “*custo* computacional” (memória necessária, tempo de cálculo e outros).

Concluindo, neste Capítulo se procurou definir as fronteiras *simbólica* e *connexionista* abrangidas pela expressão *Inteligência Artificial*, que intitula o trabalho. Mostrou-se que seria sobremaneira desejável a existência de instrumentos de medida que pudessem

auxiliar comparações quantitativas entre sistemas de IA e se formulou propostas no sentido de construir estas métricas, muito embora se enfatizando as dificuldades que se apresentam.

A primeira parte do título, isto é, a *Inspiração biológica*, será similarmente tratada no Capítulo 3. Sugestões para métrica em IAE foram postergadas para a seção 5.4.




Figura 2.1: A vida da terra na escala de um ano.

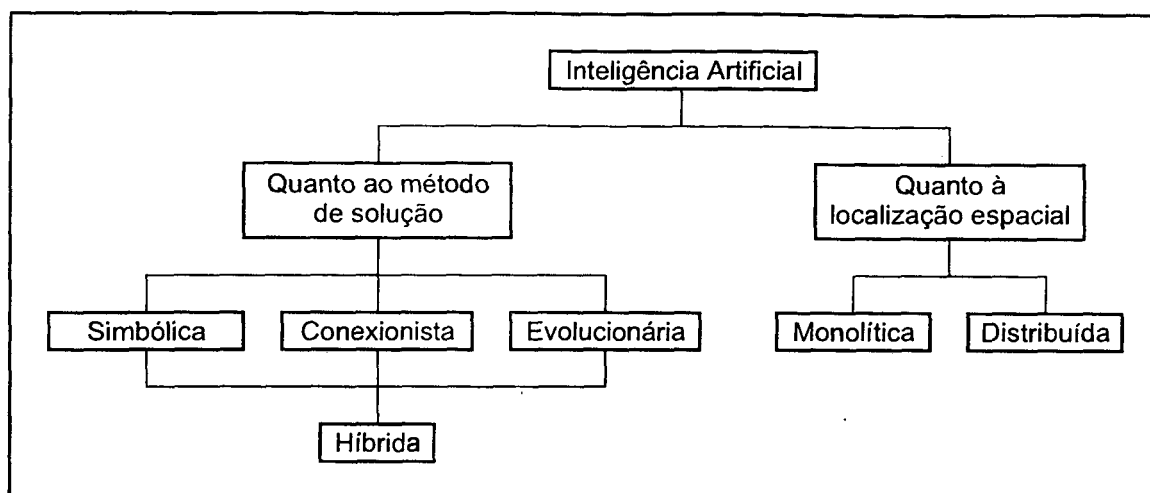


Figura 2.2: Uma proposta de classificação da IA.




Figura 2.3: Evolução dos custos de construção de SE.

Capítulo 3

EVOLUÇÃO SOB OS PONTOS DE VISTA DE DARWIN E DE PRIGOGINE

“A única coisa que sei é que nada sei ... Conhece a ti mesmo” (Sócrates)

3.1 PRINCIPAIS CORRENTES DE EXPLICAÇÃO DA NATUREZA

O Capítulo 2 se preocupou com um entorno mais abrangente da área da Inteligência Artificial e nela se ateve aos paradigmas simbólico e conexionista, citando-se apenas de passagem o paradigma evolucionário. Como o objetivo fundamental do trabalho é o estudo de uma proposta mais biologicamente embasada de um dos modelos da Computação Evolucionária, o do Algoritmo Genético, alguns fatos da evolução que inspiram e dão motivação ao uso desta ferramenta, em diversos campos, foram apontados e outros serão. Sua escolha foi baseada no intento de ilustrar mais detalhadamente a fenomenologia envolvida: a evolução. Ela engloba a construção de organismos complexos a partir de matéria inerte, o que tem sempre intrigado os cientistas.

A conjugação dos fatos observados ao longo da história conhecida do universo, como que conduz a uma leitura bastante segura de uma evolução em direção a uma maior adaptação, à otimização do uso dos recursos disponíveis, com o objetivo de atingir alvos específicos, como a manutenção da vida e melhoria de sua qualidade. O Capítulo 2 enfatiza este fenômeno como constituindo uma das componentes dos conceitos de Inteligência.

Este Capítulo 3 tem o objetivo de levantar na Natureza alguns fatos exemplificadores, notadamente os de caráter biológico, mas também alguns coletados no campo da Física, da Química e da Sociologia, que mostram a evolução. Aparentemente indicam uma derivada positiva da função que descreve a história de desenvolvimento dos seres, culminando com a emergência da inteligência. Para caracterizar esta história, alguns pontos foram arbitrariamente listados, na esperança de que melhor ilustrassem as facetas da evolução que possam interessar à sua aplicação na solução de problemas. Todavia o estudo se ateve aos

que ainda não foram devidamente considerados nas metodologias disponíveis na Computação Evolucionária, que este trabalho pretende apontar e explorar [FAL 00].

No final do século XX, um dos mais conceituados cientistas vivos, Ilya Prigogine, traz um novo enfoque dos processos evolutivos apontados pelo naturalista Darwin, propondo modelagem em termos de ferramentas analíticas. Alguns aspectos da contribuição de Prigogine, os mais diretamente correlacionados aos objetivos deste trabalho, são delineados.

Apesar do evolucionismo ser aqui adotado como hipótese básica de apoio, deve-se frisar que ele continua uma hipótese, no sentido de que não é um teorema cabalmente demonstrado, mesmo porque nas ciências não matemáticas, demonstrações inequívocas são geralmente difíceis de construir. Embora cada vez menos cientistas duvidem da proposta evolucionista, ou pelo menos em alguma de suas facetas, ainda há correntes filosóficas, credos religiosos e mesmo regiões, inclusive de países desenvolvidos, como em estados dos EUA, que proibem seu ensino em escolas públicas.

Outro exemplo: os seguidores da doutrina dos Testemunhas de Jeová não acham que a evolução tenha lógica. Seu boletim “Despertaí” [EDI 00] traz críticas veladas à conclusão a certo texto da revista *New Scientist* de que “durante sua evolução, a aranha desenvolveu técnicas muito mais avançadas do que as usadas pelo químico mais hábil”. Indaga, incredulamente, “se é lógico dizer que, pela evolução, a aranha desenvolveu técnica de fabricação tão complexa que o homem ainda não entende”.

Como parece não ter sido cabalmente demonstrado estarem errados, merecem o “benefício da dúvida”, no dizer jurídico. Antes de um maior aprofundamento no evolucionismo neodarwinista, serão vistos, a título ilustrativo, alguns dos outros mecanismos de explicação das espécies que habitam o nosso mundo.

3.1.1 Outras possibilidades de explicação da Natureza

1. MECANICISMO VERSUS VITALISMO

O estudo da Natureza, desde tempos que regredem a mais de dois mil anos, tem sido encarado sob diversos prismas como mecanicismo, vitalismo, fixismo e transformismo. No caso particular destes quatro modelos, curiosamente, eles são quase diametralmente opostos.

O mecanicismo defende o ponto de vista de que os fenômenos naturais, incluindo os relativos à vida, podem ser explicados pelas leis da Física e da Química. E então, na sua acepção, os organismos vivos são máquinas mais sofisticadas. Diz-se que são redutíveis àquelas ciências e se chamou aristotélico ou mecanicista a este enfoque, que já foi abordado com algum detalhe no Capítulo 2.

Outros defendem a visão que a vida é oriunda de algo mais que somente misturas químicas e/ou fenomenologia física e, indo ainda além, pugnam que esta diferença está fora do alcance das explicações científicas. Estes são os vitalistas platônicos [LEW 84].

A doutrina vitalista [PRI 85] tenta explicar os fenômenos e a origem da vida através da “força vital”, de natureza própria e diferente das demais manifestações conhecidas. Achava-se que todas as substâncias vivas continham esta força, que não era derivável de reações químicas e ou processos físicos. Esta hipótese perdeu terreno, à medida que os fenômenos vitais foram sendo cada vez melhor explicados pelas leis naturais dos fenômenos físicos e químicos. Entretanto, ainda tem vestígios em algumas crenças, como nas orientais, momentaneamente sob a forma do “prana”¹ em Yoga. Muitos praticantes, com tendência mística, aceitam variações desta doutrina.

Com o desenvolvimento científico, a corrente mecanicista teve crescimento avassalador, à medida que propriedades antes tidas como inerentes aos seres vivos, eram explicadas pelas leis da Química e da Física. Mas ela não conseguiu extinguir por inteiro a chama vitalista, tanto que o físico atômico Niels Bohr, prêmio Nobel em 1922 e proponente da teoria da estrutura orbital dos átomos, admitiu que os problemas biológicos não podiam ser reduzidos a fenômenos atomísticos apenas, embora estes devam ter importância profunda em sua explicação [LEW 84].

A Física Quântica reforçou esta análise “vitalista” de Bohr e ainda hoje influi nos posicionamentos dos cientistas. Richard Dawkins [DAW 00] observa que poucos conseguem entendê-la, citando o famoso físico Richard Feynmann [BRO 00b] e acrescenta que talvez por isto mesmo ela seja invocada tanto amiúde para explicar fenômenos que não têm modelagem satisfatória pelas demais teorias. Frise-se que este “vitalismo atual” é bem diferente das idéias místicas, de influências externas às ciências, e mesmo próximo a mágicas, do “vitalismo antigo”. Há os que defendem que os organismos vivos são sujeitos às leis da Física e da Química, mas que muitos fenômenos biológicos emergem espontaneamente dos fenômenos químicos e físicos, sem a eles se reduzir [WAD 62].

É interessante observar que uma propriedade emergente não é intrínseca à natureza do fenômeno observado, mas do observador. Por exemplo, quando uma peça de ferro é aquecida, os elétrons de seus átomos saltam para órbitas mais externas e depois decaem para a original, emitindo radiação correspondente à energia do salto. Inicialmente os saltos de órbitas são pequenos, de pouca energia, e quase todos iguais. Com o aumento da temperatura o salto fica “do tamanho do comprimento de onda da cor vermelha” e se vê a peça aquecida “ao rubro”. Continuando a subida do aquecimento, os saltos se multiplicam, para diferentes órbitas atômicas, cada qual irradiando frequências - cores - diferentes e sua mistura gera a cor branca (advém de todas as cores). Mas as radiações em si não têm cor, *na escala atômica não há cor*, surgindo como consequência das radiações. Aliás a cor resulta de uma interpretação dada pelo cérebro a fenômenos físicos, podendo diferentes cérebros dar diferentes interpretações ao mesmo fenômeno.

Alternativamente, a microbiologia moderna, com os avanços diários na pesquisa genética, parece ir mais e mais na direção dos que acreditam [OST 78], [LEW 84] que,

¹Em sânscrito: prana = vida.

mesmo a natureza humana, explica-se pelas predisposições genéticas. Todavia este conceito é rebatido com fatos incontestes como o de que os seres, especialmente os sociais e ainda mais os humanos, mudam várias vezes durante sua existência, especialmente devido às influências do meio ambiente, e isto quando já têm constituição genética estabilizada.

2. FIXISMO VERSUS TRANSFORMISMO

Seguindo Aristóteles [UZU 97], o pensamento humano, notadamente o ocidental, por longos séculos adotou o fixismo, que diz serem as espécies vivas, fixas e imutáveis ao longo das eras. É interessante notar que em todo o tempo em que o homem questionou suas origens, apenas nos últimos cento e cinquenta anos admitiu a possibilidade de ser fruto de uma evolução de espécies, que teria iniciado com seres unicelulares, há mais de 4,6 bilhões de anos (Figura 2.1).

Acreditava-se, interpretando de modo excessivamente literal os escritos bíblicos, e, novamente, acompanhando os ensinamentos aristotélicos, que as espécies foram criadas por alguém, prontas, fixas e inalteráveis. Esta é uma das correntes de fixismo conhecida como criacionismo. Nesta corrente de concepção dos seres vivos, eventos extraordinários, como as catástrofes geológicas ou astronômicas, explicariam o desaparecimento de espécies. O célebre caso da extinção dos dinossauros, fechando a era mesozóica, e a outra, no início da mesma era, ainda mais colossal, deixando vivas menos que 10% das espécies existentes e apenas animais com menos de 2,5 kg escaparem [UZU 97], seriam exemplos deste modelo.

Por acharem difícil aceitar a existência de um criador, continuamente a postos para providenciar espécies acabadas, que habitassem cada nova ilha surgida na face da Terra, formou-se, no final do século XIX, a corrente dos transformistas. Esta escola reconhece as transformações ocorridas no meio - diferentemente de um universo pronto e acabado desde o início, como parecem dar a entender livros como o Gênesis, na Bíblia [BÍB 87]. Este fato, em consequência, provoca mudanças nos organismos vivos que “nele se hospedam”. Estas mudanças são evidenciadas sobretudo pelo testemunho de seres fossilizados bastante diferentes dos atualmente conhecidos. As semelhanças embriológicas e bioquímicas, encontradas em alguns grupos de animais, de espécies possivelmente de mesma linha evolutiva e a ocorrência de órgãos sem função em alguns seres, ao passo que são úteis em outros, são indícios adicionais invocados como esclarecedores desta hipótese. Também a verificação das semelhanças celulares e moleculares entre as espécies, tem cada vez mais sido usada como ferramenta evidenciadora de evolução.

3. FORMAS DE TRANSFORMISMO: GRADUALISMO e CATASTROFISMO

O transformismo biológico se originou das proposições do geólogo escocês James Hutton [PIC 83], que lançou o princípio do gradualismo geológico, explicando que as grandes mudanças na superfície terrestre eram provocadas pelo somatório de pequenas

mudanças, que gradualmente levavam ao efeito observado. Estas mudanças se davam de forma lenta e contínua, em um ciclo formado pelos eventos: erosão, transporte do material erodido através de rios, ventos, etc. e consolidação dos depósitos móveis em rochas duras. Da observação do processo, cunhou a frase conhecida dos evolucionistas: “We need nothing but time”². Como bem observou Hutton [PRI 85], na evolução de entidades geológicas, o tempo é um parâmetro restritivo primordial, diferentemente do que era para a Mecânica Newtoniana. Nesta ele assume o papel de mero fator matemático, onde o passado e o futuro dos fenômenos por ela estudados eram ambos previsíveis, dadas as condições iniciais [LAP 69]. No evolucionismo darwiniano das espécies, também em áreas como fenômenos físicos, químicos e biológicos, o tempo é criador, faz história, não há retorno.

O princípio do gradualismo foi adotado por outro geólogo, Charles Lyell [PIC 83], professor, amigo e incentivador de Darwin, que mais tarde estendeu os ensinamentos do mestre aos seres vivos e criou a teoria da evolução, baseada na seleção natural. Tendo como ponto de partida evidências fósseis³, onde as espécies mais antigas são diferentes e geralmente mais simples que as atuais, nas experiências da seleção artificial, já feitas havia séculos pelos homens, com animais domésticos e em outras evidências, o naturalista inglês Charles Darwin (1809 - 1892) sistematizou cientificamente suas idéias. No livro [DAR 59], ele afirma: *Há uma seleção natural que, dada a grande variabilidade de indivíduos em uma população, premia os mais adaptados ao meio ambiente, dando-lhes mais oportunidades de sobreviverem e perpetuar sua espécie*. Este processo ficou conhecido como Teoria Evolucionista, e é das mais aceitas pela comunidade científica atual.

A ciência da Genética, inexistente na época de Darwin, trouxe duas fontes adicionais de variabilidade entre as espécies - pressuposto básico para existir evolução nesta teoria: a mutação e a recombinação genética. Somadas à seleção natural, constituem-se no hoje assim chamado neodarwinismo.

Citando em rápidas pinceladas o que é longamente tratado nos livros de biologia, tem-se a seguinte ordem para os principais eventos do evolucionismo: Os primeiros seres vivos, que no início não passavam de aglomerados de umas poucas moléculas orgânicas, com capacidade auto-reprodutiva, surgiram, presume-se, fazem 3,5 a 4,5 bilhões de anos, portanto uns 500 milhões de anos depois da formação da Terra.

O início da vida deu-se provavelmente em ambiente marinho, onde havia “a sopa inicial”, constituída de vários elementos químicos nutrientes e demais condições suficientes, como temperatura, luz, etc.. Alguns autores afirmam que “mais de 99% de nossa história evolucionária (e da maioria de nossos genes) ocorreu em um mar salgado e morno” [AHO 98]. Uma olhada superficial na Figura 2.1 indica que o percentual citado é realista. Estes organismos evoluíram para uma organização unicelular dita pro-

²Só precisamos de tempo.

³É interessante lembrar que a própria espécie humana contribui com estas evidências.

carionte, isto é, sem núcleo organizado, como as bactérias e algas azuis (cianofíceas), com várias funções adicionais, como a síntese de proteínas e respiração. Os procariontes unicelulares devem ter originado os seres eucariontes, isto é, com núcleo, há 1,5 bilhões de anos. Apesar de ainda unicelulares, a ultrapassagem deste degrau foi decisiva para o aparecimento de seres multicelulares, com divisão do trabalho entre as células e conseqüente sucesso adaptativo.

Há uns 500 milhões de anos, na era geológica chamada cambriana, os mares já tinham alguns animais invertebrados e algas multicelulares, ocorrendo então verdadeira explosão no aparecimento de novas espécies [LEW 84]. Estas posteriormente habitaram as orlas marítimas e daí provavelmente originaram todas as plantas, que por sua vez criaram um novo ambiente, rico em alimentos, possibilitando novo salto evolucionário: o advento dos animais terrestres, muito possivelmente os insetos (artrópodes), inicialmente.

Os primeiros sinais de vertebrados datam de 470 milhões de anos e os répteis de 270 milhões, originários dos anfíbios. As aves surgiram há 190 milhões de anos e os hominídeos há 5 milhões.

O *Homo habilis*, construtor das primeiras ferramentas rústicas de pedra ou madeira viveu há 3 milhões de anos e o *Homo erectus*, bom caçador, que o sucedeu, há 2 milhões.

Apenas há 120 mil anos deve ter surgido o homem moderno, da espécie *Homo sapiens*, ao que indicam todas as evidências até agora cadastradas, em algum ponto do continente africano [MIT 00], com um volume cerebral de 1.200 cm³, próximo ao do ser humano atual.

Um paralelo do tempo geológico com o ano gregoriano, ilustrado na Fig.2.1, dá uma idéia da dimensão dos intervalos de tempo aludidos acima.

Como vários vazios nas cadeias evolutivas das espécies não conseguiram ainda receber explicações razoáveis - por exemplo, como os répteis evoluíram dos anfíbios - cientistas como o biólogo americano Stephen J. Gould, teorizam que tais elos intermediários simplesmente não existem: a evolução se deu aos saltos, em certos casos, sobretudo através do acúmulo de mutações gênicas [LEW 84], o que contradiz o gradualismo darwiniano.

Outra forma de transformismo foi a adotada pelo cientista francês Jean Baptiste Lamarck, que explicou-o através de suas duas supostas leis: a *do uso e desuso* e a *transmissão dos caracteres adquiridos*. A primeira afirma que um órgão pouco usado se atrofia e desaparece e o mais usado se hipertrofia. A segunda lei admite que características adquiridas durante a vida dos indivíduos, são herdadas pelos filhos destes seres transformados. Apesar de ter tido seus seguidores, hoje é quase universalmente aceito, e pode-se dizer que totalmente no meio científico, que não há forma pela qual características somáticas adquiridas possam ser transmitidas às células germinativas -

pois os genes transmissíveis já existem no indivíduo desde o momento em que ele é zigoto (óvulo fecundado), não tendo portanto ainda somatizado características a dar em herança - e consequentemente herdáveis pela descendência.

Apesar desta impossibilidade natural, ela inspirou em IA a proposta do “Aprendizado Lamarquiano”, onde se admite a possibilidade de se incorporar diretamente aos genótipos as melhorias de aptidão experimentadas pelos indivíduos das populações, o que é visto como uma forma de aprendizado.

Este modelo representa uma violência importante e sistemática do processamento dos esquemas, como se verá, em que se baseia o AG, pois o novo genótipo é adotado com desmemorização do anterior, o que pode descaracterizá-lo [DIA 98].

Outra inspiração advinda do lamarquismo é o chamado “efeito Baldwin”, inicialmente denominado de seleção orgânica, por seu propositos J. M. Baldwin [BAL 96]. Resumidamente, constitui-se na suposição de que características adquiridas podem ser herdadas, embora indiretamente. Sua explicação baseia-se na “capacidade de aprendizado”: os indivíduos que mais fácil e rapidamente captam as mensagens do meio, não apenas em um instante, mas têm esta tendência inata, teriam mais probabilidade de procriarem e legarem como herança a capacidade de adquirir novas habilidades. Note-se que também Baldwin concorda com Darwin, em que não existe mapeamento do fenótipo para o genótipo, o que foi erradamente aceito por Lamarck (frise-se que os conceitos de fenótipo e genótipo são bem posteriores a estes cientistas, sendo usados aqui apenas como indicativos das idéias por eles defendidas, ainda que desconhecendo os mecanismos da genética).

4. OUTRAS EXPLICAÇÕES

PANSPERMIA

Já na Grécia antiga, Anaxágoras, tido como mestre de Sócrates [GAA 95], admitia a hipótese da vida estar difundida em todo o espaço, como semente em suspensão (Daí as raízes do termo: pan = tudo; sperma = semente). No início do século XX o prêmio Nobel de química Svante Arrhenius [CRA 96] teorizou que esporos de bactérias poderiam ter vindo do espaço sideral, a bordo de meteoritos, talvez. Os cientistas A. I. Oparin [OPA 55] e J. B. S. Haldane [HAL 47], de origens russa e inglesa, respectivamente, reviveram a doutrina da geração espontânea da vida, construindo uma experiência famosa a partir da mistura de substâncias químicas supostamente presentes na atmosfera terrestre (“a sopa inicial”), possibilitando o início da vida - na forma de moléculas pré-celulares auto-reprodutoras. Kelvin e Pasteur, no século XIX, já haviam demonstrado esta impossibilidade, pelo menos quanto à geração de seres mais desenvolvidos [DUB 60]. O próprio F. Crick que, com J. Watson, descobriu a dupla hélice do DNA, trabalhou nesta hipótese e não chegou a conclusões otimistas [CRI 81]. Hoje, com os conhecimentos advindos da evolução e de outras ciências, a panspermia é mais estudada como “ascendência cósmica”.

Diferentes povos e civilizações têm explicações criativas para esclarecer o aparecimento do universo e dos seres que nele habitam. Por exemplo Shiva, um dos três deuses mais adorados no hinduísmo - os outros dois são Vishnu e Brama - é o responsável pela criação e pela destruição, pela vida e pela morte, e mantém o universo em ritmo, através de sua dança.

A teoria quântica de campo preconiza que os componentes da matéria interagem pela absorção e emissão de partículas virtuais e cada partícula subatômica “é uma dança de energia, um processo vibratório de criação e destruição” [CAP 83], o que, na visão do autor, F. Capra, coincide com a dança de Shiva, já executada há milênios. Então, reprisando, não se pode descartar liminarmente uma explicação razoável, se ela não é provadamente falsa.

A idéia do evolucionismo darwiniano nasceu na escala dos fenômenos geológicos e foi expandida para as relações entre as espécies, sendo em seguida aperfeiçoada com as descobertas genéticas de Mendel. Atualmente a microbiologia traz novidades obtidas nos estudos dos genomas humano e de outras espécies, estando na ordem do dia as notícias relacionadas tanto na imprensa popular quanto na científica. As pesquisas da aplicação das ferramentas evolucionistas no entendimento da mente [MIT 00], parecem ser o último degrau deste processo “top-down”, que iniciou na escala geológica, desceu para a das espécies, daí para os genes que as compõem e parece ainda passar pelo nível atômico (e sub-atômico!), antes de atingir a escala mental. A aplicação e o desenvolvimento do mecanismo divisado por Darwin em problemas de IA, exigem que ele seja mais detalhadamente descrito, o que será feito nos próximos itens deste Capítulo.

3.2 O NEODARWINISMO

3.2.1 “Máquinas” de Darwin, Lamarck e de Vries

A evolução das espécies foi explicada por Darwin através do mecanismo de seleção, e este é, em última instância, o único mecanismo genuinamente darwiniano. De fato, os mecanismos de recombinação (“cross-over”) e mutação, só foram estudados muitos anos após a publicação de Darwin: “On the Origin of Species by Means of Natural Selection”⁴ [DAR 59], em 1859. Em sua época era muito aceita a idéia de que os descendentes eram consequência de uma combinação obtida em “uma escala contínua” dos pais: se um dos pais estivesse próximo do ótimo para uma certa variável fenotípica e o outro não, os descendentes muito provavelmente estariam no intermédio dos pais, não podendo extrapolar o intervalo definido, isto é, não poderiam ser melhores nem piores que os genitores [DIA 98], pois a variável em causa estaria “misturada”, atenuada, nos descendentes.

Mendel derrubou esta teoria “combinacional contínua” da hereditariedade e

⁴“Sobre a origem das espécies por meio da seleção natural”.

mostrou que esta se faz por meio de partículas elementares discretas - os genes [DIA 98] e os filhos poderiam ser iguais, melhores ou piores que os pais, em qualquer característica genética enfocada. Entretanto com este mecanismo não se explica o aparecimento de novas características, totalmente inexistentes até então na espécie: apenas características disponíveis no “pool genético”⁵ original podem estar presentes nos descendentes. Com a seleção natural e as leis mendelianas do cruzamento, o processo tenderia a convergir paulatinamente para o melhor indivíduo permitido pelo “pool genético” da espécie, saturando-se neste ponto, o que é matematicamente provado pelo teorema fundamental do AG, conforme se verá no Capítulo 4.

Em 1903, o botânico holandês Hugo M. de Vries publicou o livro “The mutation theory” [DIA 98], onde admitia a possibilidade de variações bruscas, o que contradizia a “lenta e gradual evolução darwiniana” e trazia à baila um novo mecanismo evolutivo, a mutação, isto é, o surgimento repentino de uma característica inexistente, mas genética, e portanto herdável. Esta nova ferramenta inventada no processo de manutenção da vida, tem a virtude de repor antigas características genéticas não mais existentes ou proporcionar novas. Como bem coloca D. Beasley [BEA 93], o cruzamento é uma ferramenta para trabalhar com o uso de material existente (“exploitation”), implementando uma busca local e a mutação permite a inserção de novos materiais, o desbravamento de territórios inexplorados (“exploration”), uma busca globalizada [TAN 95].

Em resumo se pode dizer que a seleção é um mecanismo “darwiniano”, o cruzamento é “mendeliano” e a mutação “vriesiano”. O novo conjunto, incluindo a recombinação gênica ou “cross-over”, corresponde ao neodarwinismo [UZU 97].

No tempo de Darwin e Lamarck não havia ainda sido desenvolvida a genética, o que os limitava ao estudo das manifestações físicas visíveis, isto é, ao que hoje se chama fenótipo dos seres. Com a descoberta dos genes, sabe-se que estas manifestações físicas são consequência de características genéticas e também de influências ambientais, permitindo que um mesmo genótipo exista em diferentes fenótipos e um mesmo fenótipo tenha diferentes genótipos.

Na “máquina lamarquiana” (Figura 3.1), o meio ambiente induz ativamente, provoca a criação de novos fenótipos, que são herdados pelos descendentes dos seres modificados. O meio como que enriquece os indivíduos com propriedades outrora inexistentes mas atualmente necessárias, ou alternativamente, empobrece-os retirando-lhes funções não mais necessárias.

A “máquina darwiniana” esboçada na Figura 3.2, diferentemente da “lamarquiana”, atua somente sobre propriedades existentes, agindo como um filtro, e os seres que transpõem este filtro se reproduzem e se perpetuam. Os que são retidos tendem ao desaparecimento pela falta de herdeiros.

Como mostrado na Figura 2.1, grande parte da história da vida na terra ocorreu na forma pobre de seres unicelulares, como as bactérias que se reproduzem de forma mitótica (item 3.2.2). Neste processo, os cromossomos - filamentos celulares que contém

⁵Conjunto de todos os genes de uma espécie.




Figura 3.1: Processo evolucionário segundo Lamarck.




Figura 3.2: Processo evolucionário segundo Darwin.

o material genético - duplicam-se na célula mãe, que em seguida se divide em duas células filhas, cada qual idêntica à célula original. Para Darwin, apenas as bactérias mais adequadas ao meio, o agente filtrante, seriam selecionadas para procriação. Mas a “máquina vriesiana” (Figura 3.3) enriqueceu o processo darwiniano, inserindo a nova ferramenta da mutação.

3.2.2 Mitose

Os fenótipos resultantes da reprodução poderiam, segundo a teoria de De Vries, ser iguais aos dos pais ou adquirirem características neles inexistentes. Hoje se sabe que estas modificações são possíveis, ocorrendo tanto espontaneamente, devido às próprias características do DNA que compõe os cromossomos, como pode ser induzida pelos chamados agentes mutagênicos. Destes, conhecem-se elementos químicos constituintes de drogas artificiais (os anti-virais e




Figura 3.3: A mutação no processo evolucionário, segundo de Vries.

os anti-bacterianos são muito citados pelas personalidades médicas), ou naturais (como os gases advindos de vulcões ou formados pelas descargas atmosféricas) e também fenômenos físicos, como radiações X ou raios gama. Com o passar dos milênios e o enriquecimento evolutivo das espécies de seres unicelulares existentes na terra, um novo tipo de procriação foi “inventado”. Um ser *com* determinada característica conjugava-se com outro, *sem* esta característica, e ambos geravam um sucessor *com* a característica em causa. Este fenômeno poderia ser admitido como a primeira aproximação do que veio a ser o sexo. No caso das bactérias, forma-se uma ponte, como que um canal entre a bactéria doadora da característica - a bactéria masculina - e a bactéria receptora, a feminina. Simultaneamente a bactéria masculina duplica seu cromossomo (como o faria normalmente no processo mitótico padrão, isto é, simples divisão celular em que uma célula mãe se divide em duas células filhas idênticas à mãe) e uma cópia deste passa através do canal à bactéria fêmea, que se enriquece então com uma nova constituição genética. Esta bactéria recombinante passa a se reproduzir da forma mitótica original, ou futuramente forma nova conjugação.

Como se nota, a interveniência deste mecanismo aumenta estupidamente a possibilidade de mistura de características existentes. Adicionalmente ao aparecimento de novas características com as mutações, traz sua imediata “socialização” entre os indivíduos descendentes. Talvez esta seja a causa mais importante da verdadeira explosão de espécies novas ocorrida no período que sucedeu a fase de reprodução binária.

O mecanismo relativamente simples da conjugação bacteriana foi sendo aperfeiçoado. As células constituintes do organismo de cada ser têm dois lotes de cromossomos, cada qual com o mesmo número, número este que é função de cada espécie.

Na reprodução sexuada, o pai entra com metade dos cromossomos, levada pelo espermatozóide, e a mãe com a outra metade, localizada em seu óvulo. Na fecundação o lote de cromossomos maternos se une ao lote paterno e forma uma célula dita diplóide, isto é, com dois lotes cromossômicos, o ovo. Este passa então por sucessivas mitoses, formando com o tempo todos os tecidos e com eles os órgãos do ser adulto. No lote cromossômico paterno

e no materno que formam cada célula do fenótipo do adulto, os cromossomos se arrumam aos pares, sendo cada par diferente dos demais. Os cromossomos são constituídos de genes e cada gene é responsável por uma ou mais características fenotípicas, como mostrou Mendel [DIA 98]. Eles contêm como que os projetos de construção dos organismos vivos.

O genoma de uma espécie é seu lote completo de genes. Cada um dos cromossomos de um par é dito homólogo de outro e cada homólogo contém os mesmos tipos de genes, dispostos na mesma ordem. Se na posição x , também chamada loco, de um cromossomo do par k houver um gene responsável pela “cor do olho”, no cromossomo homólogo, isto é, no outro elemento do par, seja ele k' , haverá outro gene também responsável pela característica “cor do olho”.

Chama-se alelos aos genes responsáveis por uma mesma característica, na mesma posição, de cromossomos homólogos. Assim as diversas características fenotípicas dos seres de reprodução sexuada podem ser oriundas do pai, da mãe, ou de ambos, o que ajuda a explicar o crescimento exponencial ocasionado pela “invenção” do sexo.

3.2.3 Meiose

Na formação da célula responsável pelo lote de cromossomos maternos ou paternos, chamado gameta, ocorre um fenômeno que ajuda ainda mais a miscigenação das características entre os indivíduos de uma espécie e também a criação de novas espécies. Como este mecanismo é muito explorado no paradigma de AG, faz-se aqui ligeira descrição do mesmo. Na mitose as células-filhas são cromossomicamente cópias da célula-mãe, ao passo que na meiose formam-se células que contém metade dos cromossomos da célula-mãe. Em passo inicial, a célula mãe sofre divisão mitótica onde os fios cromossômicos se duplicam formando $2n$ pares, em espécies com n pares. Em seguida, outra divisão, agora meiótica, gera quatro células a partir de uma original, cada qual com n cromossomos, por isto ditos haplóides. Ao se duplicarem, cada homólogo de um par cromossômico se divide em duas estruturas chamadas cromátides, AA' e BB' , como mostrado pelos homólogos A e B, na Figura 3.4.




Figura 3.4: Formação das cromátides na divisão meiótica.

Antes de ocorrer a mitose, as cromátides homólogas A' e B' ou A e B podem se cruzar em certos pontos Q e se soldar nestes cruzamentos, chamados quiasmas (Figura 3.5). Cada uma das quatro cromátides formará a parte cromossômica das quatro células haplóides oriundas da meiose. A cromátide A', após se separar da cromátide original A, não será mais idêntica a A, pois adquiriu os trechos Q_1B' e/ou Q_2B' , da cromátide homóloga B'. O mesmo pode ocorrer com a cromátide B', incorporando Q_1A' e/ou Q_2A' .




Figura 3.5: Processo de recombinação gênica ou “crossing-over”.

Cada cromossomo homólogo assim formado nas células haplóides não conterá apenas genes de um dos genitores do ser que está gerando estes gametas, mas de ambos. Este fenômeno é chamado de permutação ou recombinação gênica ou também “crossing-over” e potencializa ainda mais a miscigenação das características já possível pelo sexo, pois permite formação de cromossomos com trechos de origem paterna e outros de origem materna. Assim as características oriundas dos genes aparecerão em novas gerações, em combinações diferentes das que estavam presentes nas gerações genitoras. Levando-se em conta que os organismos são formados por milhares de genes (o projeto do mapeamento do genoma [BIS 90] humano situa este número entre 30 e 40 mil [VEN 01]), que se arranjam bastante livremente sobre os cromossomos, pode-se imaginar a quantidade de diferentes seres possíveis de serem formados.

Sabe-se que cada gene é um trecho de uma macromolécula de DNA, que contém o código para uma determinada proteína. Por sua vez, esta forma uma certa característica genética. A molécula de DNA é a famosa dupla hélice, constituída pelas quatro bases nitrogenadas: Adenina, Guanina, Citosina e Timina, simbolizadas pelas iniciais A, G, C e T. Existem ao redor de 3,1 bilhões de pares destas bases no genoma humano [VEN 01]. Estas são algumas razões pelas quais alguns cientistas atribuem ao acaso o maior papel de surgimento de novas espécies, e não à pressão exercida pelo meio ambiente. Diz Raymond Rasmont: “A evolução é ... filha do acaso e menos, filha da necessidade” ⁶ [RAS 83].

⁶“L'évolution est ... fille du hasard et moins, fille de la nécessité”.

Os novos conhecimentos desenvolvidos pela Biologia Molecular, pela Genética e outras ciências foram sintetizados com os ensinamentos trazidos principalmente por Darwin, Mendel, de Vries e se batizou a teoria assim renovada de “Teoria Sintética da Evolução”, ou “Neodarwinismo” [AMA 94], o que está esquematizado na Figura 3.6.




Figura 3.6: “Máquina neodarwiniana” no processo evolucionário.

O neurofisiologista William H. Calvin [CAL 94], da Escola de Medicina da Universidade de Washington, enxerga o processo evolutivo como tendo seis propriedades:

1. Opera sobre algum tipo de padrão. No caso da evolução genética, este padrão é formado pelas cadeias das quatro bases nitrogenadas A, G, C e T, do DNA; no caso dos problemas de IA, cada solução possível representa um padrão;
2. O padrão é multiplicado, através de alguma forma de reprodução, em várias cópias;
3. No processo de geração de cópias, estas devem sofrer variações, ocasionadas por mutações ou erros de cópia, embaralhamento das partes componentes do padrão, ou de outra forma;
4. As diferentes cópias devem competir por recursos escassos do meio ambiente, eliminando-se as que tiverem insucesso ou penalizando-as, de modo a que não se reproduzam tanto quanto as mais eficientes;
5. O maior ou menor sucesso reprodutivo das cópias é influenciado pelo ambiente, fato que Darwin denominou seleção;
6. A aparência da próxima geração de padrões depende de que cópias sobrevivem, para serem novamente copiadas. Algumas podem ter mais sucesso que os pais e outras menos.

Sexo e mudanças climáticas podem não ser citados entre os seis fatores essenciais do processo de Calvin, mas dão velocidade e mais opções à máquina, como já mencionado.

Reenfatizando, é imprescindível levar em conta o fator tempo, sem o qual as profundas mudanças ocorridas são incompreensíveis. De fato, as mudanças sócio-históricas importantes observadas nos grandes grupos humanos só se deram ao longo de alguns poucos milhares de anos, ao passo que a evolução das espécies ocupou centenas de milhões e a evolução da geosfera muitos bilhões de anos [NAI 83]. O perfil da curva sigmóide ou logística, muito usada para modelar a função de saída das redes neurais, pode ser usado para ilustrar graficamente (Figura 3.7) o processo evolutivo ao longo do tempo e está superposta aos períodos acima citados, no trecho do que já é história. Quanto ao trecho referente ao futuro, qual será sua forma? Reta? Exponencial? Polinomial? Qual será sua derivada? Positiva? Negativa? Nula? A evolução é uma entidade mensurável? ⁷




Figura 3.7: O fator tempo no processo evolucionário.

A mesma curva pode ser ajustada para descrever a evolução do conhecimento humano, representando o trecho inicial quase plano, os primórdios do surgimento da espécie humana, até a Idade Média. Um início de subida leve, desde então, até o século XIX e aí uma escalada vigorosa até nossos dias. Novamente neste início do terceiro milênio, o processo evolutivo, a que Darwin abriu os olhos da ciência, impõe uma interrogação trazida pela encruzilhada em que se acha este processo evolutivo. Prigogine [NIC 98], lançou sobre este problema seu frutífero esforço investigativo, mas a resposta, como se viu no Capítulo 2, ainda é mistério. *Não se sabe de onde viemos e para onde vamos!*

⁷Estas indagações sugerem desenvolvimentos futuros.

3.3 A CONCEPÇÃO DE PRIGOGINE

3.3.1 Introdução

Uma abordagem interessante para estudar e compreender um pouco mais o processo evolutivo por que passa a Natureza é sugerida nas pesquisas relativas à termodinâmica do não-equilíbrio, do prêmio Nobel de Química em 1977, Ilya Prigogine. Ele desenvolveu considerações relacionadas sobretudo com a segunda lei da termodinâmica, aplicando-a sobre os seres vivos, vistos como sistemas físicos interagindo com o meio ambiente em que estão imersos [NIC 98]. Nelas Prigogine utiliza-se da noção de equilíbrio entre os elementos componentes do sistema a ser estudado, para explorar analiticamente alguns fenômenos do processo evolutivo. O modelo proposto por Prigogine enfoca o fenômeno da evolução, encarando os organismos vivos como sistemas abertos, isto é, que trocam com o meio ambiente em que se inserem, quantidades de matéria, energia e momento [NIC 98]. Para a proposição do modelo, Prigogine exemplifica com o interessante comportamento de diversos fenômenos físicos, químicos e biológicos suficientemente simples para serem analisados em alguns aspectos, com as ferramentas da termodinâmica, mas também importantes, no sentido de serem paradigmáticos.

Supõe-se inicialmente que o sistema em causa seja modelável por uma expressão analítica que combine o conjunto $\{X\}$ de variáveis descritivas próprias do sistema. Este pode ser o conjunto de substâncias envolvidas numa reação química, ou a densidade populacional das amebas em uma cultura, ou de borboletas cinza em uma floresta londrina.

Considere-se o conjunto $\{\lambda\}$ de parâmetros típicos intervenientes no processo, como temperatura, volume, massa, partículas poluentes por m^3 de ar, etc. Um experimento físico ilustrativo, importante e comum na natureza e de implementação relativamente simples, é o da células de Bénard, onde se pode ver com clareza o conjunto $\{X\}$ e os parâmetros $\{\lambda\}$, levando o sistema a um ponto crítico.

Este sistema será a seguir descrito, para ilustrar a modelagem proposta por Prigogine ao processo evolucionário e assentar conceitos importantes nesta teoria.

3.3.2 Uma modelagem analítica da evolução

3.3.2.1 Variáveis descritivas e parâmetros restritivos no caso das células de Bénard

Suponha-se uma certa quantidade de fluido (líquido ou gasoso), mantido entre duas placas horizontais, boas condutoras de calor. No início as placas, o fluido e o meio ambiente estão à mesma temperatura e não se observa movimento (sabe-se que de fato as moléculas se movem aleatoriamente colidindo umas com as outras - o movimento browniano - e a energia cinética deste processo se manifesta na temperatura do corpo): o sistema está em equilíbrio termodinâmico, isto é, não há diferença estatisticamente importante entre duas partes quaisquer do fluido (Figura 3.8). Aplicar uma perturbação de aquecimento dT suficientemente pequeno à placa inferior, como tocá-la com a mão, não provoca aparentemente nenhuma

alteração: o movimento caótico das moléculas continua completamente desordenado e cessada a perturbação o sistema retorna à condição inicial, sem resquício de alterações, sem memória do ocorrido [NIC 83]).

Alguém que estivesse imerso neste sistema não teria meios de notar a passagem do *tempo* visto que isto só é possível se existem *mudanças observáveis* para se estabelecerem comparações referenciais. A noção de *espaço* também não existiria para esta criatura, pois que, sendo todas as partes iguais ela não teria como diferenciá-las para estabelecer a idéia de posição, e em consequência, de espaço.

Mantendo dT pequeno, o calor é transferido da placa inferior para o fluido e daí para a superior, dissipando-se então no meio ambiente, provocando um gradiente de temperatura - e então de densidade e pressão - entre as diversas camadas do fluido, com decrescimento praticamente linear. Este é o fenômeno conhecido como condução térmica, em que o sistema mantém-se em comportamento estável, com características tão “simples” como no equilíbrio (Ver 3.3.2.2).

Elevando progressivamente a diferença de temperatura dT entre as placas, ao se atingir um ponto crítico dT_C , as moléculas do líquido começam a se movimentar de forma interessante, formando como que rolos horizontais paralelos - chamados células de Bénard - com comportamento totalmente diverso do anterior, que era totalmente aleatório. Com efeito, se uma destas células se movimenta em sentido dextrógiro (horário) sua vizinha adotará o levógiro (anti-horário), como esquematizado na Figura 3.8, extraída de [NIC 98].




Figura 3.8: Mudança de comportamento de um sistema Bénard ao atingir um ponto crítico.

Este comportamento se mantém enquanto dT ficar em determinado intervalo e se este é ultrapassado, as moléculas adotam um comportamento novamente desordenado, não mais como o browniano, microscópico, mas uma caótica desorganização macroscópica chamada turbulência, em que as velocidades das moléculas variam de forma imprevisível e complexa. De fato a turbulência parece ser um aspecto de uma classe de sistemas, que sob certas condições evoluem de forma caótica.

Tanto no intervalo onde dT faz originar as células de Bénard, como na turbulência, se diz que a condução térmica do calor entre as placas é feito por convecção. Este fenômeno, que implica na transferência de calor com transporte de matéria, explica importantes fenômenos naturais, como a circulação de fluidos atmosféricos. São assim causa das mudanças meteorológicas e climáticas, das correntes oceânicas, do movimento das placas

tectônicas, que, por sua vez, ajudam a explicar as formações dos continentes e a própria evolução da vida. A convecção também explica alguns fenômenos solares, observando-se as grandes movimentações de massa devido a diferenças de temperatura entre as crostas do sol e de outras estrelas.

Um indivíduo imerso em um sistema de Bénard teria elementos para observar tanto a passagem do tempo, através da constatação das mudanças ocorridas no seu entorno, como do espaço, o que poderia ser notado pela contagem do número de células formadas em um intervalo qualquer. É interessante notar a complexidade organizada dos movimentos simples e desordenados das moléculas em que se transforma um sistema antes caótico, cuja única causa foi a aplicação de uma mudança em um parâmetro restritivo do meio ambiente: a temperatura. O exemplo ilustra que os conceitos de caos, complexidade e ordem, antes mais do interesse das ciências biológicas, passaram a trazer luzes no estudo de fenômenos físicos e poderão ser aproveitados para o estudo de organismos vivos.

A variação - ou evolução - no tempo dos processos físicos, químicos ou biológicos como o acima deverá obedecer à forma:

$$dX/dt = F_x(\{X\}, \{\lambda\}) \quad (3.1)$$

onde:

$\{X\}$ = Conjunto de variáveis descritivas do fenômeno;

$\{\lambda\}$ = Conjunto de parâmetros restritivos impostos pelo meio: fluxos de matéria, energia ou informação que o sistema troca com o ambiente (Ex.: temperatura, densidade de partículas, quantidade de alimento disponível).

Levando-se em conta apenas uma variável descritiva, X_i , que na realidade representa um conjunto de n variáveis, ter-se-ia um conjunto de n equações, com esta forma geral. Focando apenas uma variável descritiva do conjunto $\{X\}$, se ela não evolui, isto é, se mantém constante ao longo do tempo considerado, o sistema fica em equilíbrio estacionário em relação à mesma. Em outros termos, fica inalterado com relação ao movimento browniano das moléculas, à taxa de nascimento, à densidade populacional ou qualquer que seja a variável descritiva considerada.

Então:

$$dX_i/dt = 0$$

e

$$F_x(\{X\}, \{\lambda\}) = 0$$

Se o processo for representável por apenas uma variável descritiva X_1 e sujeito a dois parâmetros restritivos a e b , e ainda, que a evolução seja linear, então esta é representável por:

$$dX_1/dt = aX_1 + b \quad (3.2)$$

No caso estacionário se tem a reta solução:

$$aX_1 + b = 0 \quad (3.3)$$

A variável descritiva X_1 vale $-b/a$ no equilíbrio estacionário do processo evolutivo, mas ela pode ser obtida de forma única, dado o valor do parâmetro b , em qualquer outro estado do sistema, esteja ele em equilíbrio ou não. Por outro lado, pode-se imaginar que, com a variação do parâmetro restritivo λ , em um determinado momento, o sistema adota solução diferente que a condução aproximadamente linear do calor entre as placas. Como se descreveu, esta solução poderá ser uma célula levógira ou dextrógira. A representação gráfica de um fenômeno ainda caracterizado por uma única variável descritiva X_1 e por um único parâmetro de controle λ , com os diversos valores b_i , poderia tomar a forma da Figura 3.9 [NIC 83].




Figura 3.9: Multiplicidade de soluções em função dos parâmetros de controle.

Observe-se a variação do parâmetro λ : enquanto $\lambda < b_c$ o sistema se comporta como se fosse linear, previsível, mas ao atingir o valor crítico $\lambda = b_c$, o sistema chega a uma bifurcação ([BAK 92]) e então pode escolher entre várias soluções, estabilizando-se nos estados descritos por X_1 ou X_2 , para o mesmo b_c . Vê-se ainda que várias soluções X_i são possíveis à medida que λ vai de b_c a b_3 , quando novamente uma única solução de X se verifica. Então, no intervalo $b_c \leq \lambda \leq b_3$, o sistema adota um comportamento onde várias soluções possíveis podem ocorrer, mas, de antemão não se pode dizer qual ocorrerá.

Para evoluírem, isto é, sofrerem mudanças, os sistemas devem ser abertos, isto é, interferem e sofrem interferência do meio em que se encontram e podem ser englobados em um modelo de processo onde três etapas sobressaem [NIC 83]:

1. O sistema aberto parte do equilíbrio e pode ser
 - a) Perturbado por agentes externos e/ou
 - b) Sofrer flutuações internas;
2. O sistema evolui para um estado em que o parâmetro λ , ultrapassando um limiar crítico λ_c , provoca sua instabilidade;
3. No ponto de instabilidade o sistema faz uma “escolha” entre os caminhos a seguir: as soluções (geralmente duas), da variável descritiva do processo. Diz-se então que houve uma *bifurcação*.

Escolhido um caminho, o sistema atinge um novo estado de equilíbrio e volta ao passo 1.- O registro dos passos 1, 2 e 3 do processamento, forma a história do sistema, que pode ser representada pela Figura 3.10, formando uma estrutura arborescente semelhante aos gráficos filogenéticos, montados pelos naturalistas na modelagem da evolução das espécies.

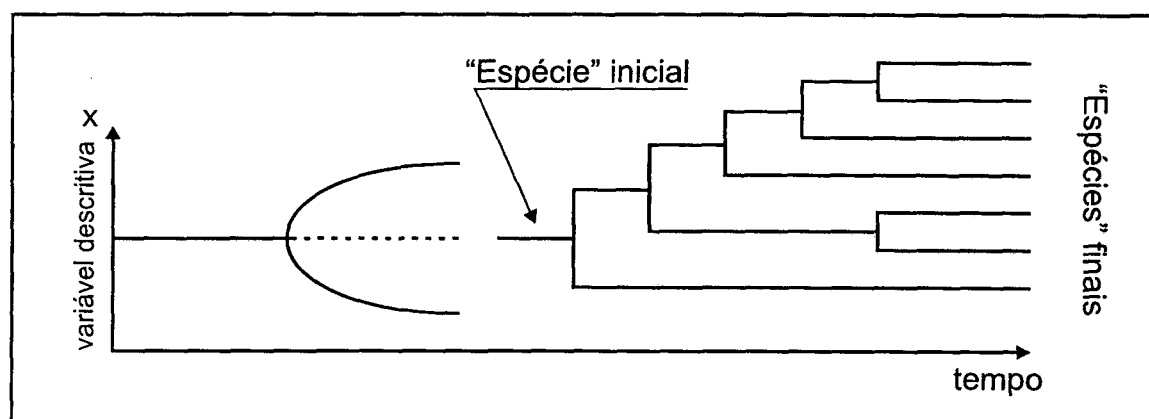


Figura 3.10: Bifurcações no processo evolutivo.

Frise-se que, para existir evolução, os sistemas devem ser irreversíveis, não retornando ao estado inicial após cada variação; devem ainda ser não lineares, permitindo várias soluções sob determinadas restrições impostas, representadas pelos parâmetros restritivos.

A este processo, em analogia aos sistemas anteriormente denominados “máquinas de Darwin, Lamarck e De Vries”, chamou-se aqui “máquina de Prigogine”. A seguir serão vistos os conceitos mais importantes nela inseridos. O gráfico da Figura 3.10 pode ser gerado facilmente com a modelagem do movimento browniano de partículas, que, aliás, lembra bem os entrechoques dos indivíduos de uma população em evolução [DIN 00].

3.3.2.2 Principais conceitos envolvidos na modelagem analítica

• EQUILÍBRIO E ESTABILIDADE

A noção de equilíbrio é muito importante no estudo da evolução e deve ser estabelecida com algum detalhe. Na Mecânica Newtoniana define-se equilíbrio estático ou estado de repouso como a propriedade de um sistema, isto é, uma certa quantidade de matéria, em que todos os seus pontos têm velocidade e aceleração nulas em relação a outro sistema de referência. O equilíbrio termodinâmico, por sua vez, é entendido como a inexistência de diferença entre a temperatura de um sistema e a de seu referencial. Note-se que em ambos os casos as moléculas constitutivas dos sistemas se movem continuamente (a menos que estejam próximas ao zero absoluto), mas aqui apenas a escala “macroscópica” é considerada.

Não havendo diferenças de temperatura, não há tendência de ocorrer mudança espontânea no estado termodinâmico entre sistemas. O estado de um sistema é caracterizado por determinados valores de algumas propriedades mensuráveis (as variáveis descritivas) - como pressão, temperatura, volume, massa - ou calculáveis a partir dos valores mensurados - como a energia interna, oriunda principalmente do movimento das moléculas. As leis clássicas da Natureza valem para situações próximas do equilíbrio, ao passo que longe dele as flutuações internas ou as perturbações externas (parâmetros descritivos) exercem papel importante, tornando a matéria mais criativa, por assim dizer [PRI 96]. Em outra obra Prigogine coloca isto textualmente, dizendo: “Tudo o que ela toca - a física clássica - seca e morre. Morre para a diversidade qualitativa, para a singularidade, para tornar-se simples consequência de uma lei geral” [STE 84].

As leis da termodinâmica, assim como outras leis físicas, geralmente são aplicáveis em situações em que o sistema modelado trabalha em regiões próximas ao equilíbrio. Prigogine, em contraposição, fez estudos estendendo a teoria da termodinâmica para casos onde os sistemas se afastam de forma importante da zona de equilíbrio e onde grandes diferenças fenomenológicas ocorrem. Sua análise demonstrou que uma nova forma de estruturas ordenadas podem existir, nestas regiões, longe do equilíbrio. Denominou-as “estruturas dissipativas” com o intuito principal de frisar que elas só ocorrem em conjunto com o meio ambiente que as engloba. Estas estruturas são encontráveis no mundo dos fenômenos químicos, físicos, biológicos e mesmo sociológicos, como se exemplificará.

Um sistema está em equilíbrio estável se uma perturbação, mesmo que não negligenciável, será seguida por um retorno ao estado anterior. No equilíbrio instável, pelo contrário, uma perturbação não implica em processo em sentido inverso, para anulá-la, mas o processo inicial induzido pela perturbação será amplificado mais e mais, no mesmo sentido da perturbação. Diz-se que há “*feed-back*” *positivo*, ou *retroação positiva*. Os engenheiros têm cuidado quando seus sistemas apresentam “*feed-back*” positivo, pois geralmente tais estruturas são auto-destrutivas e, sintomaticamente, projetam formas de contornar estes casos. Há situações, entretanto, em que ele é benéfico, como no

relógio a pêndulo, onde este, a cada oscilação, recebe um impulso da mola ... e oscila. Em funcionamento normal, se uma entrada, uma perturbação externa, provoca uma saída em que uma de suas componentes é reaproveitada para anular a entrada, isto é, tem efeito contrário a ela, o sistema é conhecido como de *retroação negativa* (“*feedback negativo*”) e em um ponto o equilíbrio é restabelecido. No caso da retroação ter o mesmo sentido que a entrada, esta se reforça a cada ciclo e leva o sistema cada vez mais para longe do equilíbrio. O sistema de fato funciona como amplificador da entrada inicial.

Em sua abordagem, Prigogine encara os sistemas evolutivos cujo equilíbrio pode ser passível de alteração, devido a flutuações internas, ou perturbações advindas do meio ambiente, ou ambas.

Dentre os vários estados possíveis de um processo evolutivo, apenas os estáveis, pela razão citada, têm condição de se materializar [PRI 85].

• NÃO LINEARIDADE

Os sistemas naturais são geralmente não lineares, no sentido de que os efeitos não são direta ou inversamente proporcionais às causas: não guardam relação de proporcionalidade com as mesmas. Consequentemente a aplicação de restrições advindas do meio, leva-os a pontos críticos em que várias soluções podem ser adotadas e esta multiplicidade caracteriza a complexidade destes sistemas, para Prigogine. Repisando o conceito determinista, visto no Capítulo 2, da Mecânica Newtoniana, sabendo-se as causas, os efeitos estavam definidos, o que foi “comprado” por Einstein, conforme diz claramente com sua famosa frase: “Deus não joga dados”⁸. Prigogine é contra este determinismo, colocando que as razões que permitiriam a predição do desenvolvimento futuro do sistema não estão dadas. Ao contrário dos sistemas da mecânica clássica, que mantém uma memória dos estados iniciais, que lhes permite o retorno, a reversão histórica, neste caso não existe memória, sendo o sistema implacavelmente tanguido pela irreversibilidade. Este leva-o até o seu destino futuro incerto e imprevisível, pois as condições que permitiriam sua predição ainda não existem, elas irão se formar no instante exato da bifurcação.

O prejuízo estupendo de mais de dez bilhões de dólares causado por um simples vírus feito por um jovem estudante filipino [TOF 00], indica uma forte existência de correlação não linear entre causa e efeito. O enriquecimento, em poucos meses, de estudantes ainda quase adolescentes, abençoados com alguma idéia que o mercado globalizado e eletronicamente conectado julga financeiramente interessante, são apenas alguns sinais exemplificadores de que a economia industrial está em um momento de revolução e indica o desvio de rota para o ramo da informação.

Vê-se ainda que a riqueza dos mundos possíveis é muito maior que a do mundo real, isto é, o que de fato aconteceu como solução evolutiva poderia ter ocorrido de muitas

⁸“God does not play dice”.

outras formas, o que parece ser indicado pelas árvores filogenéticas das espécies (Figura 3.10). Mas há autores [LEW 84] que parecem não concordar, dizendo que os seres atuais seriam parecidos com os que se teria se outro caminho evolutivo fosse percorrido, pois eles representam pontos atratores.

- **COMPLEXIDADE**

A generalidade dos fenômenos evolutivos têm uma característica a que a literatura denomina complexidade, no sentido em que são necessários diversos componentes paramétricos e variáveis de estado, para que o equilíbrio fique ameaçado e estes devem ser inter-relacionados, conectados, isto é, as diferentes variáveis de estado não sejam totalmente independentes. Como a diversidade implica em alguma desordem e a conexão em alguma ordem, a complexidade reside em algum ponto entre ambas. Um sistema que não seja completamente desordenado, isto é, que obedeça a leis estatísticas que podem descrevê-lo (“caos determinista”), nem completamente ordenado, que o tornaria determinístico e portanto previsível, uma vez que as leis que o regem sejam encontradas.

No caso da informática, os cientistas adotam uma medida aproximada de complexidade, que leva em consideração, em última análise, o tempo mínimo para executar um número de operações necessárias para realizar um processo sobre n dados. Se o processo exigir um número proporcional a n^i , se diz que é da classe $O(n^i)$, sendo i uma potência inteira [BRO 00a]. Existem outras várias concepções de complexidade e no caso de organismos vivos, como em informática, há os que consideram mais complexos os seres que adquiriram maior capacidade de processar informação sobre o meio em que vivem, podendo assim reagir adequadamente às mudanças porventura supervenientes. Entretanto há que se lembrar que há uma espécie de molusco marinho com apenas um neurônio, que é usado para controlar a procura de um local adequado à sua sobrevivência. Quando o mesmo é achado, este “cérebro uni-neuronal” fica supérfluo, sendo digerido, já que torna-se mais útil como alimento que como processador de informação. Neste sentido, as bactérias têm também baixa complexidade, pois são unicelulares, embora sejam muito adaptadas às suas funções, sendo dos organismos mais antigos e numerosos da Natureza.

Outra forma de se encarar a complexidade é a de considerá-la como uma medida a ser tomada na escala de evolução dos organismos, como escreveu Darwin “o mais simples não pode evitar de tornar-se mais complexo e se procurarmos pela origem primeira, deve haver progresso” [LEW 84].

Prigogine adota a concepção de diversidade de opções para uma situação, como os pontos de bifurcação dos fenômenos, para conceituar complexidade [PRI 85].

- **EFEITO BIFURCAÇÃO**

Independente do grau de sofisticação em que o efeito Bénard seja modelado experimentalmente, ao ser atingido o limiar dT_c , algumas células adotam o sentido dextrógiro de

rotação enquanto outras, suas vizinhas, o levógiro, sem que se possa controlar a adoção de um ou de outro sentido e somente a aleatoriedade explica o fato. Diz-se que neste caso o sistema chegou a um ponto de bifurcação em dT_c e a história de como a evolução futura de tal sistema se dará, depende de qual solução seja adotada em cada ponto de bifurcação.

Um exemplo de processo social que evolui para uma bifurcação é o das agitações como guerras e revoluções. A Revolução Socialista de 1917, na Rússia, derrubando o regime monárquico ou a de 1964 no Brasil, são exemplos onde se vê um padrão comum: os acontecimentos normais da sociedade organizada, como funcionamento das instituições estabelecidas, obediência às leis, mecanismos econômicos estáveis, entre outros, são rompidos, gerando-se uma convulsão que leva as estruturas a se redefinirem e se estabilizarem em outros patamares, diferentes dos que lhes deram origem e de natureza totalmente imprevisível. Os movimentos coletivos dos cardumes, os ciclos de corrente do sol, a organização do miocárdio na fibrilação [BAY 98] também representam mudanças importantes no comportamento padrão, após a ultrapassagem do ponto crítico de algum parâmetro restritivo.

• ATRADORES

A fixação em determinadas soluções entre as possíveis, verificada nos sistemas complexos, recebe o nome de atração e os pontos de fixação destas soluções, de *atratores*. Há modelos que simulam formalmente este processo, usando conceitos desenvolvidos por Liapunov [NIC 98].

No caso da biologia, a seleção guiaria o desenvolvimento dos organismos para as situações que fossem compatíveis com a manutenção e com a melhoria da qualidade de vida dos mesmos, o que se poderia imaginar como pontos de atração do processo evolutivo. Para alguns cientistas como Brian Goodwin, da Open University, Inglaterra [LEW 84], uma reedição do Big Bang teria como um dos efeitos a provável produção dos mesmos 92 elementos químicos hoje conhecidos. Similarmente, a explosão do Cambriano, que destruiu todos os animais vivos com mais de 2,5 kg, daria origem a seres muito parecidos com os que hoje habitam a terra, pois estes seriam formados por atratores existentes no espaço de possibilidades morfológicas [LEW 84].

Nos fenômenos termodinâmicos ocorridos em sistemas fechados, isto é, que não trocam energia e/ou matéria com o meio, a evolução só seria possível com o crescimento da entropia interna, até o equilíbrio (pois a 2ª lei garante que em tais sistemas a entropia não pode decrescer), que exerce o papel de atrator (Ver 3.4.2).

Como nos casos ilustrativos da “máquina de Prigogine”, alguns padrões de comportamento bem definidos podem emergir espontaneamente e de forma randômica, como efeito da interação dos indivíduos componentes do sistema. Alguns autores [BEV 99] chamam de *auto-organização* a este fenômeno e são consequência da variação de determinados parâmetros de controle. Ao atingirem determinado valor, na bifurcação, as

não-linearidades inerentes ao funcionamento do sistema, agem como amplificadores destes parâmetros, tendo como consequência o surgimento dos padrões de *auto-organização*, notados tanto no tempo quanto no espaço.

Estes padrões (*atratores*) podem ser uma forma de explicação para inúmeros fenômenos evolutivos, por exemplo:

- 1 - Autores, como Brian Goodwin [GOO 92], teorizam que os órgãos construtivos dos seres devem sua formação à interveniência de “atratores no espaço morfológico das espécies, que as ‘facilitam’ ” [LEW 84]. Esta é uma explicação radicalmente diferente da de Darwin, para quem estes órgãos derivam de estruturas que ocorrem por mero acaso e foram selecionados para constarem permanentemente no sistema, por terem se mostrado úteis em certas circunstâncias. Num exemplo já proverbialmente citado na área, Darwin [DAR 59], faz conjecturas sobre a evolução possível de um órgão tão complexo como o olho.

Outro autor [CHU 88] teoriza: *“Se, por mutações genéticas, a superfície sensível à luz se curvar sobre uma cavidade hemisférica, suas porções seletivamente iluminadas fornecerão informação direcional a respeito das fontes e oclusões de luz, informações estas que podem acionar respostas motoras direcionais... Num próximo passo a cavidade hemisférica pode se transformar em uma cavidade esférica, com as células sensíveis à luz, no fundo, ... e eis, ‘miraculosamente’, um olho formado”*.

- 2- As sociedades podem ser vistas como padrões de comportamento oriundos das interações dos seres individuais que as compõem, sejam elas formadas por ninhos de formiga [BEV 99], colméias de abelhas [TAH 86], [WIE 82], estouros de boiadas a um simples ruído, ou as diferentes escalas de organizações humanas, como grupos, tribos, cidades, estados, etc. [BUC 00].

A evolução é usada por alguns autores para explicar fenômenos psicológicos [MIT 00]. Nesta abordagem, os casos de pânico podem ser vistos como uma bifurcação comportamental, proveniente do fenômeno de a mente atingir certos pontos críticos, no controle dos pensamentos.

3.4 A EVOLUÇÃO E AS LEIS DA TERMODINÂMICA

3.4.1 A três leis da termodinâmica

Cada ser vivo pode ser visto como um sistema físico, sujeito às mesmas leis que valem para as máquinas térmicas, como as locomotivas ou os motores a explosão, para as quais as três leis da termodinâmica foram inicialmente propostas.

Estas leis podem ser assim descritas:

- 1ª Lei: A energia total de um sistema é constante, ou, parafraseando a lei da conservação das massas, de Lavoisier (Nada se perde, nada se cria, tudo se transforma): “A energia não pode ser criada nem destruída”.

Na termodinâmica se diz que, quando se entrega a quantidade Q de calor a um sistema, este realiza o trabalho W e varia sua energia interna em ΔU , tendo-se $Q = \Delta U + W$, sendo ΔU a energia associada ao movimento randômico das moléculas do sistema e às forças intermoleculares. Assim este primeiro princípio relaciona, de forma quantitativa, o calor Q entregue e a quantidade W de trabalho equivalente (chamado equivalente térmico do trabalho [RUI 65]) realizado por um sistema - seja ele uma máquina térmica - ou um ser vivo.

- 2ª Lei: também chamada princípio de Carnot-Clausius: Em um sistema isolado, é impossível a passagem de calor de um corpo frio para um corpo quente sem auxílio de uma agente externo.
- 3ª Lei: Walter H. Nernst postulou, em 1906, que “a entropia de materiais cristalinos perfeitos é, por definição, nula a zero Kelvin” (-273° Celsius). Como consequência desta lei, o zero absoluto é inatingível, pois quanto mais um corpo se aproxima dele, tanto mais difícil se torna extrair-lhe energia, para baixar sua temperatura.

Se o calor fluísse livremente de um corpo quente para um frio e também em sentido inverso haveria reversibilidade, mas a 2ª lei garante que a transferência de calor entre sistemas é um processo irreversível. Diferentemente da primeira, que se refere à *quantidade* de energia do universo, a segunda traça uma *relação qualitativa entre trabalho e calor*, afirmando que é mais fácil transformar trabalho em calor que o inverso, isto é, o calor é uma forma degradada, mais desorganizada, mais “entropizada”, de energia. Apenas uma parte da energia do sistema mais quente se transforma em trabalho, sendo a outra depositada como “forma de pagamento” em uma fonte mais fria. Esta é parte não utilizável na transformação, e quanto maior, mais irreversível é o processo. O calor depositado na fonte fria pode eventualmente se transformar em trabalho, se houver uma fonte ainda mais fria que ela, permitindo um novo salto térmico, e assim sucessivamente, até que a fonte fria atinja $0K$ (zero Kelvin), o zero absoluto.

Então, olhando-se o universo como um sistema isolado, isto é, não trocando energia nem matéria com nenhum outro, as fontes quentes que o constituem vão entregando calor às fontes intermediárias e estas às mais frias. Sucessivamente, num processo de degradação da energia - cujo montante total não varia, como diz a primeira lei - todos os subsistemas componentes do universo se estabilizariam em uma mesma temperatura de equilíbrio, nenhuma transformação sendo mais possível e se teria a *morte térmica*, conceituada por Clausius.

Este processo evolutivo, prenunciado pela 2ª lei, traz o nascimento de discussões científico/religiosas interessantes, como a afirmação de A. Estrada em [RUI 65]:

“Para nós, o aumento de entropia nas transformações reais não tem como consequência a morte do universo. Sabemos que Deus existe e é distinto do universo e sobre ele atua. O universo não é um sistema isolado”.

Embora não no sentido usado por A. Estrada, deve-se dizer que não se conhecem sistemas isolados de fato, uma vez que a ação da força da gravidade e do eletromagnetismo, por exemplo, não encontram isolantes conhecidos. O que se faz é admiti-los isolados, como abstração hipotética, na formulação de leis como as da termodinâmica.

Prigogine se baseou nas leis da termodinâmica para fundamentar sua formulação analítica.

A visão da morte inexorável prevista pela 2ª lei tem influenciado profundamente o conceito que o homem faz de si mesmo, como o de um “deus caído” que procura se erguer, como bem mostra a pergunta de Leon Brillouin: “Como é possível entender a vida quando todo o mundo é regido por uma lei que aponta para a morte e para o aniquilamento?”. Mas Prigogine não olha sob este ponto de vista e também se faz a pergunta “o universo como um todo está propenso a uma evolução cíclica ou está condenado a uma degradação irreversível?” [PRI 85]. Neste sentido Prigogine e Nicolis [NIC 98] argumentam que os fótons, elementos componentes mais importantes da entropia, surgiram nos primeiros estágios da formação do universo e conseqüentemente, ao contrário do que afirma a 2ª lei, “a morte térmica ficou para trás”, e, no tempo, a evolução da vida está para frente.

Aqui também se vê que não estão respondidas as perguntas “*de onde viemos?*” e “*para onde vamos?*”.

3.4.2 Entropia

Todos os eventos ocorridos no universo, desde o cair de uma folha, até o aparecimento de uma estrela supernova, isto é, qualquer fenômeno natural, seria explicável por meio de leis eternas e imutáveis. Uma vez que elas fossem dominadas, o futuro e o passado seriam deduzidos com sua aplicação. A citação de Laplace em 2.1.3.2 expressa este sentimento. À procura destas leis, as ciências têm investido grande esforço, embora hoje novas teorias tenham surgido, aventando a hipótese de que não existe esta possibilidade. Por mais que se conheça o funcionamento da Natureza, parece que sempre haverá em evidência o elemento imponderável, probabilístico [PRI 85]. Em perspectiva oposta, grandes cientistas, como Einstein, são adeptos de leis universais (Ver sua famosa expressão, citada em 3.3.2.2). Andam à busca de “teoria de tudo” (2.1.3.2) como se buscou o “santo graal”, a “pedra filosofal”, a criptonita.

Voltando à segunda lei da termodinâmica, ou teorema de Carnot-Clausius, se tem que a integral da relação entre a quantidade de calor absorvida ou entregue por um corpo que sofre um ciclo reversível e a temperatura absoluta no estado inicial A e no estado final B , deste ciclo é nula. As equações 3.4 e 3.5:

$$\int_{AMB} dQ/T - \int_{ANB} dQ/T = 0 \quad (3.4)$$




Figura 3.11: Variação da energia térmica em ciclo reversível.

logo,

$$\oint dQ/T = 0 \quad (3.5)$$

formalizam o processo e a Figura 3.11 [RUI 65] traz um esquema das evoluções verificadas em sistemas gasosos, tendo-se nas ordenadas a pressão p e nas abscissas o volume v .

De fato, as integrais de 3.4 são iguais e independem dos caminhos AMB e ANB , mas apenas de A e de B e *estas integrais definem a função entropia nos estados inicial A e final B* . Esta função estabelece um conceito de caráter matemático não perceptível sensorialmente ou mesmo mensurável diretamente. É uma grandeza dependente de variáveis de estado (pressão, temperatura, densidade, concentração de reagentes químicos, etc.), sendo *sempre crescente enquanto durar a evolução do processo a que o sistema estiver sujeito*. Zeugner, em [RUI 65] chamou, metaforicamente, de peso do calor a esta função, pois um corpo que tenha peso G e caia da altura h_2 para h_1 realiza o trabalho $W = G(h_2 - h_1)$. Também um corpo que “caia” da temperatura T_2 para a T_1 realizará o trabalho $A.W = \Delta S(T_2 - T_1)$, onde:

$$A = \text{equivalente térmico do trabalho (A = 1 kcal/426,66 kgm)}$$

e

$$\Delta S = \text{variação entrópica entre os estados } T_2 \text{ e } T_1.$$

Se um corpo sofre uma transformação reversível passando do estado A ao B (Figura 3.11), estando a uma temperatura absoluta T , nos deslocamentos infinitesimais dl ele

trocará com o meio ambiente a quantidade infinitesimal de calor dQ (pois conforme Carnot: um corpo passa de um estado a outro, tomando Q_1 calorias do corpo quente e entregando Q_2 calorias ao corpo frio). A relação entre o calor infinitesimal trocado com a temperatura T dará o quociente: $dS = dQ/T$.

Somando todas as expressões acima em todos os intervalos dl de A até B , se tem:

$$\int_A^B dS = \int_A^B dQ/T = \int_{AMB} dQ/T = S_A - S_B = \Delta S_{AB} \quad (3.6)$$

No caso de ciclo fechado, isto é, reversível, o ponto final B coincide com o inicial A e:

$$\oint dQ/T = \Delta S = 0$$

3.4.3 Processos reversíveis e irreversíveis

De forma inversamente proporcional, a entropia indica a ordem de um sistema: se a entropia aumenta, também cresce sua desordem. Em um *sistema isolado*, sem trocas com o meio ambiente, se teria (Figura 3.12) a variação de entropia total dS dada por:

$$dS/dt \geq 0$$

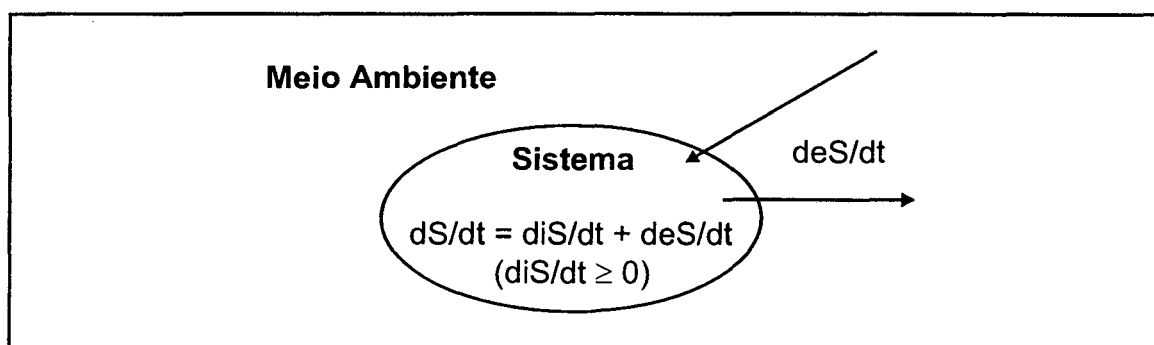


Figura 3.12: Componentes da entropia em sistemas abertos e fechados.

Na mesma Figura 3.12, se o sistema for *não isolado*, tem-se duas componentes para a entropia [PRI 85]:

$$dS/dt = diS/dt + deS/dt \quad (3.7)$$

A primeira parcela, diS , da equação 3.7 se refere à variação da “desordem interna” (*entropia interna*); a outra, deS (*entropia externa*), é proveniente da troca de matéria e energia com o mundo exterior. O sistema isolado é caso particular de 3.7, onde:

$$deS/dt = 0$$

e se tem:

$$dS/dt = diS/dt \geq 0 \quad (3.8)$$

Assim, o sistema isolado só aumenta sua entropia em função de “evoluções” que se façam em seu interior, até um máximo. Então, um sistema que se organiza, não pode ser fechado. O equilíbrio, conseguido quando não há trocas entre o sistema e o meio, é um estado de máxima desordem e será impossível o aparecimento de comportamentos ordenados, complexos, como os dos fenômenos físicos encontrados nas células de Bénard, nas reações químicas de Belousov-Zhabotinski (ver em 3.5.3), ou em fenômenos biológicos, como os citados em 3.5.2. Em outras palavras, *será impossível a evolução*.

Em contrapartida, em sistema aberto, a contribuição do mundo exterior não é nula, isto é, deS pode ser negativa ou positiva, conforme características próprias do sistema em análise. Pode-se pois ter $dS/dt < 0$ em um sistema aberto, isto é, uma *possibilidade de evolução*, de diminuição de desordem [NIC 83].

A 2ª lei afirma que os processos físicos isolados descem inexorável e irreversivelmente para o estado de desordem, têm sua energia degradada, isto é, aumentam sua entropia. Este fato é verificado pela tendência irreversível da equalização das temperaturas e inexistência de dispositivo capaz de transformar calor em trabalho sem perdas. Embora a energia seja globalmente conservada - pelo primeiro princípio - uma parte dela se dissipa irrecuperavelmente. Esta lei de certo modo encontra contradição na Natureza, onde se vêem processos que resultam em organizações melhores. A própria vida, aliás, parece ter evoluído de seres uni a pluricelulares, daí aos insetos, peixes, anfíbios, vertebrados, ..., homem.

Prigogine, através de seus estudos, mostra que, recebendo energia e ou matéria de fonte externa, sistemas não lineares, por ele chamados de “*estruturas dissipativas*”, podem chegar a situações de instabilidade e auto-organização, com funções previsíveis apenas probabilisticamente. Esta linha de análise trouxe luzes para novas pesquisas, incluindo a teoria do caos e da complexidade.

3.4.4 O tempo e a entropia

Em um pequeno instante de tempo dt , a variação da entropia em um sistema é dada pela soma das duas parcelas da equação 3.7 e o 2º princípio garante que $diS \geq 0$. As transformações internas poder ser reversíveis ou irreversíveis. Estas advêm sobretudo do atrito intermolecular, condução do calor, reações químicas, etc. e geram a entropia.

Um efeito suplementar importante é o de indicar um sentido para o tempo, já que, se $dt > 0$ (indicando intervalo de variação do passado ao futuro), se terá $diS \geq 0$ [NIC 83]. Se o sistema é isolado, então $deS/dt = 0$ e a evolução, isto é o conjunto de modificações ocorridas no sistema, será sempre com entropia crescente e levará fatalmente ao estado de equilíbrio, quando terá seu valor máximo. A entropia é assim uma grandeza que mostra se um processo é ou não reversível. Se um sistema isolado sofre uma transformação irreversível, então sua entropia aumenta. Se a transformação é reversível a entropia fica

constante, mas esta transformação é ideal, não ocorre na Natureza. Na realidade, numa transformação que fosse completamente reversível, não se verificaria estabilidade referida em 3.3.2.2: haveria um desequilíbrio infinito de ida e volta entre os estados inicial e final [RUI 65].

O 2º princípio traz uma nova forma de se estudar os fenômenos do universo pois as leis da mecânica clássica, até então disponíveis consideravam os movimentos dos sistemas mecânicos como passíveis de ocorrerem indistintamente do passado ao futuro, ou vice versa, como o afirmou Lapalace [LAP 69]. Como “o calor (energia) não pode, por si mesmo, passar de corpo frio a corpo quente”, conforme o teorema de Carnot-Clausius, a troca de calor entre dois corpos é irreversível.

Além da definição conseqüente da 2ª lei, a entropia pode ser conceituada pelas abordagens:

1. *Da estatística*: Os trabalhos de Plank, Gibbs, Boltzmann utilizam esta visão [PRI 85].
2. *Da teoria da informação*: Claude Shannon também usou este conceito [SHA 48]. As idéias de “medida de desorganização” e de “ordem lógica” fazem-se presentes também nestes enfoques.

3.5 FATOS DA NATUREZA ILUSTRATIVOS DAS “MÁQUINAS” DE DARWIN E PRIGOGINE

3.5.1 Introdução

Um fato interessante é que o motor rotativo não foi “descoberto” pela natureza, enquanto o alternativo (tipo pistão), foi. Com efeito, apenas uma exceção é conhecida: a proteína - tubulina- que tem uma extensão protoplasmática tipo cauda giratória. Com esta “hélice rotativa”, ela nada. Alguns protozoários e mesmo certas bactérias, também apresentam flagelos ou cílios que são usados para locomoção ou captura de alimento, mas com movimentos muito primitivos [LOP 98]. Por outro lado, a actina/miosina tem movimento de sobe/desce, como de pistão.

Outra constatação é que proteínas, em geral, como o DNA, têm hélices estruturais que giram para a direita. Existem poucas exceções conhecidas.

Por que estes fatos ocorrem? Estatisticamente seria de se esperar que 50% fossem à direita e o restante à esquerda. O modelo de Prigogine pode ser invocado para modelar estes fenômenos naturais.

3.5.2 Exemplos biológicos

Pode-se encontrar exemplos que se assemelham às transições verificadas nos fenômenos químicos e físicos, também em seres vivos e seu estudo é uma abordagem que pode ajudar a compreensão dos mecanismos pelos quais tenha a evolução se tornado possível e, adi-

cionalmente, tragam novas ferramentas para resolução de problemas. Abaixo se descreve sucintamente alguns.

1. EXEMPLO BIOLÓGICO - *Dictyostelium discoideum*

A *Dictyostelium discoideum* é uma ameba que funciona como um sistema aberto, pois se alimenta e excreta. Em condições normais, os indivíduos de uma cultura destas amebas se comportam como organismos individuais, apresentando reprodução por divisão celular e simulam um sistema homogêneo, isto é, a densidade dos indivíduos é a mesma em qualquer ponto da cultura. A aplicação de uma restrição exterior, como, por exemplo a diminuição dos elementos nutritivos abaixo de um certo limiar, provoca alteração profunda no comportamento das amebas: as células se reúnem em estruturas organizadas com poder de locomoção e assim adquirem a chance de procurar melhores condições de sobrevivência. No trajeto de busca, o novo organismo se altera, adquirindo uma parte o formato de base e outra de cabeça. Esta, em certo instante, explode, espalhando seu conteúdo, constituído de esporos, que, encontrando boas condições, formam novas amebas.

O fenômeno da bifurcação é aqui observado no instante em que as amebas unicelulares, explorando o meio ambiente, “decidem” seu futuro, adotando uma de duas formas exclusivas completamente diversas: prosseguir como seres unicelulares com multiplicação por divisão celular, ou adotar a estrutura pluricelular e reprodução por esporulação.

A *Dictyostelium discoideum* é tema de eventos específicos, como a International *Dictyostelium discoideum* Conference, onde J. Strassmann [STR 00] disse que estes seres usam certo tipo de inteligência para trapacear e sobreviver, com o mecanismo referido acima.

2. EXEMPLO BIOLÓGICO - ENFOQUES EVOLUTIVOS EM INSETOS

- a) Um caso clássico é o das borboletas, dos arredores de Londres onde as do tipo cinza predominavam sobre as pretas, quando as árvores eram cobertas de líquens. As cinzas se mimetizavam com o meio ambiente, escapando mais facilmente dos pássaros predadores. A fuligem, proveniente da Revolução Industrial, escureceu o tronco das árvores, o que inverteu o processo, e as pretas passaram a predominar. As cinzas eram mais facilmente percebidas sobre fundo escuro das árvores enegrecidas [UZU 97]. Aqui a cor do habitat foi o parâmetro variável que provocou a bifurcação na variável “densidade populacional” das borboletas [NIC 83].
- b) As sociedades de insetos têm atraído o estudo dos cientistas da área de IA, como o “homem das formigas” [LEW 84] Edward O. Wilson, um dos autores do famoso livro “The Ant” ([HOL 90]). Este afirma que as formigas estão no topo da evolução dos insetos, como o *Homo sapiens* está no topo dos vertebrados, o que se deve sobretudo ao processo de sociabilização coletiva que desenvolveram. Potencializaram a habilidade de processar informação [LEW 84], o que, agindo retroativamente, possibilitou a sofisticação da sociedade.

A bibliografia é muito rica em trabalhos que estudam as sociedades de insetos e que tentam aplicar a forma de solução adotada nestas sociedades a problemas “quaisquer”. Por exemplo, em [BEV 99] se faz um interessante estudo de um modelo que sugere a existência de um ponto ótimo entre a possibilidade de as formigas irem com precisão às fontes alimentares, diminuindo o tempo de coleta destes alimentos, e a de simultaneamente existirem formigas que “errem o caminho” até as fontes conhecidas, o que permitiria à colônia a descoberta de novas fontes. Parece que, devido ao sucesso evolucionário atingido pelas formigas, este número ótimo entre os dois casos, foi encontrado por elas.

O fato de que, na floresta tropical brasileira, a biomassa de formigas é quatro vezes a de todos os vertebrados reunidos e que, perfazendo apenas 2% do total de insetos, os conhecidos como ‘sociais’ atingem um total superior a 50% da biomassa de insetos, são apontados como evidência deste sucesso [LEW 84]. Assim não seria, talvez, má idéia a cópia da sua solução em problemas como o da interação entre agentes que atuam em ambiente heterogêneo e imprevisível, como em uma rede de computadores ou como um veículo no sistema viário de uma cidade [BEV 99].

- c) Outro caso interessante de evolução nos insetos é o das abelhas. Nas sociedades apícolas, a rainha é a única fêmea da colméia com órgãos de reprodução totalmente desenvolvidos. É a mãe de todos os membros da família, pois é a única que põe ovos (os fecundados dando origem a abelhas femininas e os não fecundados originando os zangões). Os zangões farejam uma rainha virgem até a dez quilômetros e quando ela está em época de cópula, aceita relação com até dez machos, que lhe fornecem quantidade de esperma suficiente para uma média de um ano de postura. Neste ato os zangões “deixam sua vida em holocausto a este inimitável gesto de amor” [WIE 82], fato ainda mais interessante quando se sabe que eles não têm pai. Nascidos de óvulos não fecundado pelos zangões que copularam com sua mãe (o que caracteriza reprodução partenogênica), só têm avô materno, pois que a rainha sua mãe nasceu de ovo fecundado normal. Este é um caso típico, dos raros, em que há relativa sincronia em relação ao fim da geração masculina geradora e o nascimento da gerada.

As mesmas abelhas, na construção de seus favos, constituídos de alvéolos prismáticos hexagonais, dão outro belo exemplo ilustrativo da precisão evolutiva a que pode chegar a Natureza, na solução de seus problemas. A forma hexagonal, além da triangular e da quadrada, são as três que permitem ser justapostas, de forma que as paredes de prismas adjacentes sejam comuns e não deixem espaços intersticiais vazios, o que seria inevitável com prismas cilíndricos, por exemplo. Entretanto, adotando a forma hexagonal, as abelhas conseguem, com a mesma cera gasta na construção dos favos, um ganho de 50% no volume, em comparação com o prisma triangular. Caso adotassem o prisma quadrado ganhariam apenas 30%⁹.

⁹Estes números são facilmente obtidos sendo admitido que o perímetro da base a dos três prismas seja con-

Ainda mais chocante é a sofisticação, aliada à simplicidade, adotada no fechamento dos prismas. O cientista francês René Antoine F. de Réaumur - inventor do termômetro de água e álcool e da escala termométrica que leva seu nome - no início do século XVIII, notou que todos eram fechados com três losangos de ângulos agudos internos constantes. Independentemente da origem dos alvéolos, sua medição resultava sempre em $70^{\circ}32'$. Testou, fazendo observações em alvéolos construídos por abelhas oriundas de países como França, Alemanha, Canadá, Suécia, Inglaterra e mesmo das Guianas.

O matemático escocês Collin MacLaurin, também conhecido pelo desenvolvimento de funções em séries, provou, calculando o volume do alvéolo em função do ângulo agudo do losango, que este valor é justamente o que fornece maior volume, com aproveitamento máximo do material. Com um mínimo de cera que, na confecção de um quilo, consome seis quilos de mel (o produto básico destes insetos), conseguem matematicamente maximizar o volume dos favos [TAH 86].

Estas comprovações parecem fortalecer a proposta de que a pesquisa em Computação Evolucionária deva ser mais “orientada” para as “soluções naturais”.

3.5.3 Exemplos químicos

O fenômeno da bifurcação é “universal”, no sentido de que pode ser encontrado nos diversos ramos da ciência. Para ilustrar, cita-se um exemplo famoso constituído por uma reação química de oxidação do ácido malônico ($CH_2(COOH)_2$) causada pelo bromato de potássio ($KBrO_3$), catalisada pelo sulfato de cério ($Ce_2(SO_4)_3$), tudo dissolvido em ácido sulfúrico (H_2SO_4). A mistura é feita em um reator que administra os reagentes em dosagens adequadas às proporções estequiométricas e os agita convenientemente, ao mesmo tempo em que retira os produtos formados.

Tal sistema funciona como verdadeiro relógio químico colorido, com momentos onde a mistura fica ora amarela ora incolor, em ciclos regulares. Esta bifurcação é causada pelo excesso de íons Ce^{4+} , provocando o amarelo, ou de íons Ce^{3+} , que provocam mistura incolor. Controlando as restrições, consegue-se ainda o regime caótico e também o de múltiplos períodos [PRI 85]. Este processo é conhecido como reação de Belousov-Zhabotinskhi [NIC 98]. O mesmo pode funcionar também em sistema isolado, isto é, sem adição de reagentes nem remoção de produtos e então a oscilação de cores se verifica até certo momento após feita a mistura, quando o sistema se homogeneiza, estabilizando-se em uma só cor. Este é um padrão encontrável em uma série de outras reações químicas.

stante, indicando a mesma quantidade de cera disponível nos três casos, o que levaria a lados de comprimentos a , $3/4a$ e $a/2$ para as bases triangular, quadrada e hexagonal, respectivamente e a volumes de $4a^2\sqrt{3}h$, $9a^2h$ e $6a^2\sqrt{3}h$.

3.5.4 Exemplos sociológicos e psicológicos

Os processos exercidos pelas “máquinas” de Darwin e Prigogine parecem estar presentes em áreas onde há elementos interagindo de forma semelhante à do movimento “Browniano”, isto é, onde partículas componentes em suspensão em meio fluido se movem, devido a entrechoques, de forma contínua e randômica. Fenômenos psicológicos e sociológicos, como os citados em 3.3.2.2, *mutatis mutandis*, podem ser enfocados sob este ângulo.

As guerras, avalanches, engarrafamentos, epidemias, incêndios florestais [BUC 00], são outros casos em que as características apontadas por Prigogine, como a não linearidade entre causa e efeito, a bifurcação, estão presentes e podem ajudar à sua compreensão.

Os lucros estupendos ou os prejuízos fabulosos, exemplificados no item 3.3.2.2, possibilitados pela economia globalizada, onde há, com os modernos meios de comunicação, sempre mais interligação entre os indivíduos, são outros casos da interação exercida pelos organismos entre si e com o meio ambiente, levando à evolução.

3.6 CONCLUSÃO

Ao contrário dos sistemas deterministas da mecânica clássica, que mantém uma memória dos estados iniciais que lhes permite retorno, reversão histórica ([LAP 69], [PRI 85]), nos sistemas evolutivos não existe este sentido de memória. Eles são sujeitos a fluxos de matéria e/ou energia que os “empurram” para longe do ponto de equilíbrio.

O conceito de bifurcação é documentado de diferentes formas nas civilizações. Os chineses através do simbolismo do *Yin* e do *Yang*, que representam os extremos da Natureza, em equilíbrio dinâmico e harmonioso, onde o maniqueísmo não tem guarida. Nem tudo é completamente branco, nem completamente preto, bom ou mau, vida ou morte, etc., mas em um estado há a semente do seu antípoda [CAP 83].

As concepções evolutivas lançadas por Hutton, Darwin, Mendel, de Vries e outros, cada dia mais comprovadas nos estudos científicos, bem como uma proposta de sua formalização, foram esboçadas neste Capítulo. O intuito foi o de assentar as bases e definições conceituais das ferramentas que serão utilizadas no Capítulo 4. Lá se abordará metodologias de procura de pontos ótimos em espaços de soluções, inspiradas no processo evolucionário aqui esboçado.

Capítulo 4

COMPUTAÇÃO EVOLUCIONÁRIA

“Natura non facit saltus”¹

4.1 INTRODUÇÃO

Nos Capítulos anteriores, os ramos de pesquisa da Inteligência Artificial Simbólica e Conexionista foram vistos em aspectos gerais. Neste Capítulo será abordado o ramo da Inteligência Artificial Evolucionária - IAE, terceira entre as classificações de IA propostas na Figura 2.2. Relembrando o problema de desuniformização de conceitos e de terminologia, as publicações preferencialmente chamam a IAE de Computação Evolucionária - CE, razão pela qual esta denominação também é aqui utilizada. Sendo um pouco mais rigoroso, frisa-se que a IAE é uma abordagem de estudo da IA que integra, com a IAS e a IAC os três paradigmas hoje mais pesquisados da área. Estão afetos a este segmento da IA, entre outros assuntos, a psicologia, os fenômenos da emergência e do aprendizado. Em contrapartida, a CE é um ramo da Ciência da Computação, que se apropria de alguns operadores da genética para buscar solução de problemas.

A ótica será frisar os aspectos do paralelismo possível entre os métodos de solução de problemas adotados pelos paradigmas atuais de Computação Evolucionária e os encontrados na Natureza, de onde, em princípio, se originam.

A sistemática da IAS era de derivar conhecimento a partir de relativamente poucas regras gerais inseridas nos sistemas, uma abordagem do geral para o particular². Como se apontou rapidamente, em IAC as informações devem emergir como consequência da “aplicação e interação massiva de regras simples, usadas paralelamente” [MIT 96]. Esta é também, como se verá neste Capítulo, a abordagem em que se baseia a Computação Evolucionária, isto é, do particular para o geral³.

Todo o texto tem o objetivo primordial de ser uma tentativa de “retorno à Natureza”, “de volta à origem”. Nela se nota que problemas difíceis, como por exemplo o

¹ A Natureza não dá saltos - Leibnitz

² De cima para baixo: “top-down”, no jargão de informática.

³ De baixo para cima: “bottom-up”.

da locomoção das espécies bípedes, foi resolvido com brilho muito maior que a mais moderna tecnologia. Nesta, só despontou alguma solução, quando se juntou o trabalho de equipes multidisciplinares, como fisiologistas, engenheiros, programadores, etc. Séculos após a invenção da muleta, soluções mais naturais, isto é, mais copiadas da Natureza, parecem ser uma boa saída.

Na realidade, o Capítulo é uma expansão, até um nível de detalhe julgado suficiente para atender a ótica citada, do texto e do tema tratado no artigo [FAL 00], submetido a evento do IEEE em novembro de 2000. Lá se expôs a público as razões “filosófico-técnicas” que motivam este trabalho. Aqui elas serão estendidas e mais formalizadas, com o fito de alicerçar o desenvolvimento algorítmico a ser efetivado no Capítulo 5.

Assim, se procura caracterizar alguns pontos onde os paradigmas de Computação Evolucionária, nas implementações até hoje disponíveis, não se preocupam em seguir com mais cuidado os processos já construídos pela Natureza. Serão trabalhados mais longamente apenas os modelos mencionados no subconjunto “Computação Evolucionária” da Figura 4.1. De fato, nesta Figura se pode ainda notar outros elementos como Sistemas Fuzzy, Vida Artificial, formando com a Computação Evolucionária a área que também é conhecida como Inteligência Computacional [BEZ 94]. Esta, unida a outros temas, como Geometria Fractal e Sistemas Complexos, estão construindo um grande campo de pesquisa ainda não muito bem definido quanto às suas fronteiras - e mesmo quanto a seus conteúdos. Para fins de referência, aqui se chamou, Computação Natural a esta abrangente área, mais uma vez sublinhando o papel do fio comum que passa por todas estas abordagens, a saber, sua inspiração em processos naturais. Ademais, estes contornos, indefinidos de certa forma, como que copiam o comportamento geral da Natureza, onde dificilmente há limites totalmente precisos, bem definidos.

A Lógica Fuzzy, desenvolvida formalmente a partir dos anos 60 do século XX, substituiu a dicotomia simples anteriormente adotada na Lógica Clássica. O “valor verdade” de uma proposição, que até então só poderia ser ‘verdadeiro’ ou ‘falso’, é substituído por uma “escala de valor verdade”, onde uma afirmação pode ter de 0 a 100% de “valor verdade”. Estes estudos são já aproveitados em uma série de áreas bastante sedimentadas, como Sistemas Fuzzy, Controle Fuzzy, Matemática Fuzzy, Teoria da Decisão com Abordagem Fuzzy, constituindo-se em objeto de congressos internacionais ⁴.

Na seqüência, serão vistos com olhar panorâmico os componentes do conjunto *Computação Evolucionária*, mostrado na Figura 4.1, o que permitirá a posterior comparação entre o que se conseguiu com estes métodos e o que a “mãe Natureza” poderia talvez ainda nos oferecer.

Seguindo o exemplo dos criadores das metodologias IAS e IAC, outra corrente científica emergente mais uma vez foi beber na fonte da Natureza as idéias para a solução de problemas relativos ao “domínio da inteligência” ou de outros. Fala-se aqui especificamente da fonte biológica. Esta metodologia de ataque de problemas foi sugerida em

⁴Exemplo: “7th. Fuzzy Days” (International Conferency on Coputacional Intelligence, Universität Dortmund, Oct. 1-3, 2001, <http://ls1-www.cs.uni-dortmund.de/fd7>).

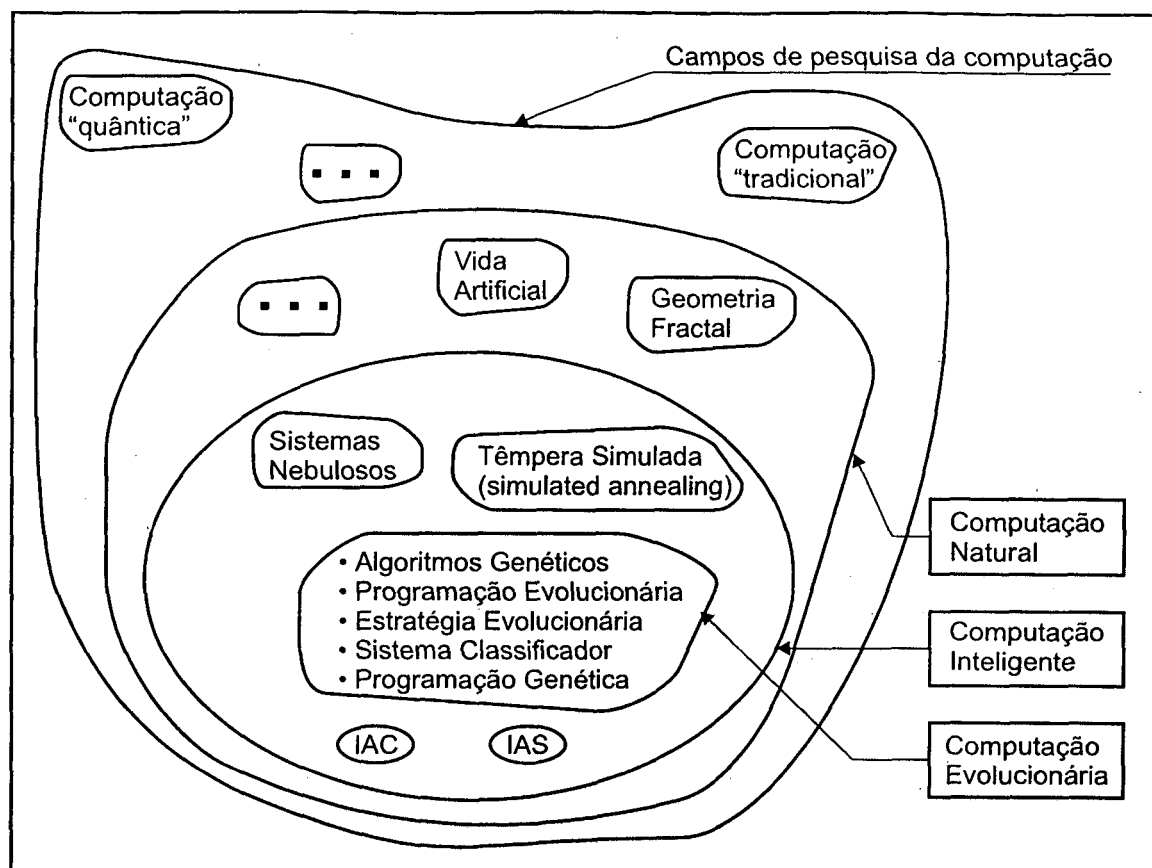


Figura 4.1: Computação Natural - Áreas de estudo inspiradas na Natureza.

1975, com o trabalho de John Holland [HOL 75]. Inspirando-se na reprodução sexuada e simulando a evolução supostamente seguida pelos seres vivos, criou a área denominada Algoritmos Genéticos. A inspiração veio de Darwin [DAR 59], que, no século XIX, lançou a teoria da evolução das espécies, através da sobrevivência dos mais aptos.

Baseando-se na mesma linha de raciocínio - a inspiração na evolução natural das espécies - outras propostas de metodologias já haviam surgido nas décadas de 60 e 70 do século passado e, como os Algoritmos Genéticos, são geralmente englobadas sob um grande manto, com o nome genérico de Computação Evolucionária. Além dos Algoritmos Genéticos, pode-se citar como paradigmas de “raiz evolucionária”, razoavelmente aceitos pela comunidade acadêmica, os seguintes métodos de busca ou de otimização: Programação Evolucionária, Estratégias Evolucionárias, Programação Genética e Sistemas Classificadores (Figura 4.1).

Embora de forma diferenciada entre os diferentes paradigmas, os fenômenos naturais de Reprodução, Seleção, Recombinação e Mutação formam os assim chamados “operadores básicos”, através dos quais diversas soluções são pesquisadas alternativamente. À semelhança dos entes vivos em evolução, interagem em um ambiente definido e têm sua performance monitorada de forma a permitir que os mais aptos sobrevivam e assim gerem nova prole, supostamente mais adaptada ao meio, construindo no processo uma solução melhor

que aquelas de onde a sistemática iniciou.

Com respeito ao pioneirismo destas idéias, existe documentação sobre outras pesquisas feitas nos fins dos anos 50 e início dos 60, sobre algoritmos inspirados na evolução, mas que não tiveram a atenção adequada da comunidade científica e, em razão disto a seqüência na pesquisa ficou prejudicada [MIT 96].

A enumeração destas metodologias não é assunto totalmente sedimentado. Citando outros exemplos, Bäck & Schwefel [BÁC 93] e Mitchell [MIT 96] consideram a existência de apenas três paradigmas principais de algoritmos advindos da evolução natural: Estratégias Evolucionárias, Programação Evolucionária e Algoritmos Genéticos. Na mesma publicação, Bäck & Schwefel salientam ainda que a “evolução em direção a regiões cada vez melhores de espaço de busca é feita por processos randômicos de seleção (às vezes determinísticos), mutação e recombinação (este completamente omitido em alguns paradigmas)”. Enfatizam ainda a capacidade destes três paradigmas de produzir soluções aproximadas muito boas, “mesmo em casos de problemas de otimização complicados, com superfícies de resposta móveis, podendo ser multimodais, descontínuos, não diferenciáveis e com ruídos”.

A omissão da Programação Genética e Sistemas Classificadores talvez se explique por estes serem casos especiais de Algoritmos Genéticos [TAN 95].

Na visão geral de cada paradigma que se fará neste Capítulo, serão cobertos com algum detalhe os itens: aplicações, história, descrição geral e fundamentos teóricos.

4.1.1 Outras técnicas “naturais”, mas não evolucionárias

Além das técnicas existentes na “área evolucionária”, são utilizadas outras metodologias de solução de problemas de busca e otimização, advindas da Natureza, todas supondo que se dispõe de uma função de aptidão (“fitness”) a otimizar (maximizar ou minimizar).

Abre-se aqui um parêntese para esclarecer a acepção em que está se tomando esta expressão e elucidar um equívoco muito cometido: confundir grau de adaptabilidade e de aptidão. Uma função de *adaptabilidade* ou de *adaptação* mede a flexibilidade de um organismo a se manter viável em diferentes ambientes. Outra função, a de *aptidão* (chamada de função “fitness” na literatura especializada em inglês), mede o quão bem equipado está um organismo para viver e evoluir em um meio ambiente específico, seu habitat. Para seres com alto grau de adaptabilidade é mais viável atingir altos graus de aptidão. O inverso não é verdadeiro. Exemplificando, o urso panda tem alto grau de aptidão ao meio ‘floresta de bambus’, mas tem baixo grau de adaptabilidade ou de adaptação, pois morre facilmente em outro ambiente.

A menos que explicitamente indicado, é à função de aptidão que se faz referência neste trabalho, pois geralmente é a um meio bem determinado que se fazem as pesquisas.

Pode-se citar inicialmente a *Busca Randômica* ou *Busca Enumerada*, em que os pontos do espaço de solução são selecionados aleatoriamente - ou conforme alguma sistemática - e sua aptidão é calculada. É uma forma mais ou menos “cega”, um processo pouco elaborado, que se justifica se os pontos a testar são em número viável.

Tabela 4.1: Método do Gradiente: Valores em R e R^n .

	Domínio		Contradomínio
derivada	$(f : R \rightarrow R)$	\longrightarrow	$(f' : R \rightarrow R)$
gradiente	$(f : R^n \rightarrow R)$	\longrightarrow	$(\nabla f : R^n \rightarrow \forall \in (R^n, R))$

Os *Métodos de Gradiente* são mais elaborados que os de busca randômica e se baseiam na derivada de funções bem comportadas, para orientar a direção da busca da solução. Precisando melhor, como derivada e gradiente operam sobre R e R^n , tem-se as implicações mostrada na Tabela 4.1.

Se a função tiver descontinuidade ou pontos angulosos [BRA 99], o método pode falhar.

Os métodos conhecidos como *Subida de Encosta* ou *Escalada*, funcionam adequadamente em funções com apenas um pico (unimodais), mas no caso de funções multimodais, elas podem estacionar em pontos sub-ótimos. Para alguns casos há desenvolvimentos famosos na bibliografia, como o método *Tabu* [GLO 89] que combina o paradigma *Subida de Encosta* com heurística, construída para evitar que o sistema não fique preso em soluções sub-ótimas ou mesmo a ocorrência de ciclos intermináveis. Isto é feito mantendo-se uma memória dos ótimos locais visitados recentemente (denominados pontos Tabu) e proibindo o algoritmo de novamente testá-los [GLO 97].

Na *Busca Iterada* se combina os dois métodos anteriores: randomicamente seleciona-se pontos e quando se acha um adequado aplica-se a *Subida de Encosta*. Apesar da simplicidade, o método não fornece uma visão geral da superfície de busca ou superfície de solução, além de procurar com igual intensidade em regiões de alta como de baixa aptidão, o que o AG, por exemplo, evita, concentrando suas buscas em regiões mais promissoras, pelo menos teoricamente.

O método “Simulated Annealing” [KIR 83], geralmente com tradução livre no material de referência especializado para *Têmpera Simulada* [MAZ 99], lembra o método da *Subida de Encosta*: seleciona-se um ponto aleatoriamente $((I, f(I))$ na Figura 4.2) e se faz um movimento de valor também aleatório $(I'' = I + \Delta x)$ na superfície de busca. O novo ponto é aceito caso leve a uma solução melhor. Inicialmente mesmo movimentos que levem à piora (“movimentos negativos”, dando $f(I') < f(I)$, como para $I' = I - \Delta x$) são aceitos. À medida que o processo segue, “movimentos negativos” são paulatinamente proibidos.

A analogia é feita com o resfriamento controlado utilizado na “têmpera de aços”. Variações deste tratamento, quando utilizado em metalurgia, são conhecidas como têmpera ou recozimento, dependendo de que características se deseja obter no produto final. Quando aquecidas até o ponto de fusão, as moléculas dos corpos sólidos, especialmente os metais, organizam-se em estrutura muito mais livre que nas condições normais. São, em seguida, resfriadas vagarosamente, em ambiente controlado, de forma a dar tempo a que as moléculas se organizem em estrutura uniforme, que exijam o mínimo de energia. Ocorre que, à medida que o tempo passa, este sistema perde energia (Conforme conceituado em




Figura 4.2: Têmpera simulada: Variação dos valores da função de aptidão.

3.3.2.2) e as moléculas permanecem mais fixas às posições ocupadas. Em outras palavras, no método simulado, cai a probabilidade de que sejam aceitos “movimentos negativos”, que se distanciam de um ótimo detectado. A estratégia de se aceitar, nos estágios iniciais, soluções que pioram a situação atual, tem como objetivo escapar de máximos locais.

Como na *Busca Randômica*, este método trata um ponto de cada vez, não fornece assim uma visão panorâmica da superfície de soluções.

Frise-se que este paradigma se inspira em fenômeno termodinâmico, fenômeno físico, enquanto a maioria dos demais é de origem biológica.

4.2 ESTRUTURA GERAL DOS PARADIGMAS DE COMPUTAÇÃO EVOLUCIONÁRIA

Conforme mostrado no Capítulo 3, o modelo evolucionário observado na Natureza engloba necessariamente um processo em que cinco elementos sobressaem:

1. Meio ambiente com recursos limitados;
2. População de organismos que habitam o meio ambiente, consumindo alguns de seus recursos e geralmente entregando outros, ao mesmo tempo que se multiplica [NIC 98] (Ver discussão sobre Entropia em 3.4.2);
3. Ocorrência de “erros de cópia”, ou de modificações no processo de multiplicação;
4. Competição entre os organismos, pelos recursos escassos do meio ambiente;
5. Eliminação dos menos aptos, em consequência da competição.

Tabela 4.2: Paralelo entre conceitos da Biologia e de Computação Evolucionária.


<i>Biologia</i>	<i>Algoritmos Genéticos</i>
Cromossomo	Cadeia, cromossomo, indivíduo, solução
Gene	Variável, caractere, bit
Alelo	Valor de uma variável/caractere/bit
Locus	Posição da variável na cadeia

Em cada paradigma de Computação Evolucionária estes elementos estão mais ou menos explicitamente presentes, e normalmente estão propostos em forma algorítmica, cuja estrutura tem uma apresentação geral razoavelmente padrão para todos. Esta estrutura será a seguir mostrada, sendo inicialmente proposta uma nomenclatura e formalização simbólica comum aos paradigmas. Esta formalização é sugerida em [BÄC 93].

4.2.1 Definições e notações

A Figura 4.3 esquematiza um sistema evolucionário, embora nem todos os elementos que compõem o modelo sejam representáveis.

Em termos algorítmicos, os paradigmas de Computação Evolucionária podem ser formalizados por um modelo genérico comum, cuja estrutura, se passará a ver, juntamente com a terminologia envolvida. A Tabela 4.2 traça um paralelismo entre termos usados em Biologia e em Computação Evolucionária, principalmente no paradigma de AG.

**Figura 4.3:** Sistemas evolucionários: elementos principais.

NOTAÇÃO	DESCRIÇÃO
I	Conjunto de indivíduos possíveis (organismos): superfície (espaço) de busca (ou de soluções) ou População
R	Conjunto dos reais ou outro com ordem completa ([FAL 01a])
$\vec{a} \in I$	Um indivíduo qualquer de I (geralmente \vec{a} é definido por um vetor \vec{x} de variáveis, e $\vec{x} \in R^n$)
$f : I \rightarrow R$	Função aptidão. Mapeia cada \vec{a} , através do seu genótipo, no seu fenótipo
$P(t) = (\vec{a}_1(t), \vec{a}_\mu(t))$	Subconjunto de I , chamado população, em um instante t
$P'(t), P''(t), P'''(t)$	Populações intermediárias, auxiliares, no algoritmo
μ	Número de indivíduos da população genitora
λ	Número de indivíduos da população gerada
$r : P^\mu \rightarrow P^\lambda$	Operador de recombinação ("cross-over"), aplicado sobre indivíduos da população genitora (P^μ)
$m : P^\lambda \rightarrow P^\lambda$	Operador de mutação, aplicado sobre indivíduos da população gerada (P^λ)
$s : (P^\mu \cup P^{\mu+\lambda}) \rightarrow P^\lambda$	Operador de seleção (aplicado sobre a população gerada, acrescida ou não da geradora)

Um algoritmo evolucionário genérico pode então ser assim formalizado, segundo proposta inspirada em [SCH 87].

4.2.2 Algoritmo evolucionário genérico

ALGORITMO EVOLUCIONÁRIO GENÉRICO (linguagem livre)

```

 $t := 0;$ 
inicializar:  $P(0) := \{\vec{a}_1(0), \dots, \vec{a}_\mu(0)\} \in I^\mu;$ 
calcular:  $P(0) := \{f(\vec{a}_1(0)), \dots, f(\vec{a}_\mu(0))\};$ 
ENQUANTO (critério de parada) FAÇA
  recombinar:  $P'(t) := r(P(t));$ 
  mutar:  $P''(t) := m(P'(t));$ 
  calcular:  $P''(t) := \{f(\vec{a}_1''(t)), \dots, f(\vec{a}_\lambda''(t))\};$ 
   $t := t + 1;$ 
  selecionar:  $P(t+1) := s(P''(t));$ 
FIM ENQUANTO

```

O critério de parada da iteração poderá ser o número de gerações, o tempo de processamento, o grau de convergência estipulado, uma medida de saturação (série de ciclos, sem que haja ganho de convergência), etc. Chama-se geração à população envolvida em cada laço do algoritmo.

4.3 ESTRATÉGIAS EVOLUCIONÁRIAS

Em 1964 e 1965, Ingo Rechenberg e seu colega Hans-Paul Schwefel ([BÄC 93], [SCH 65]), da Technische Universität Berlin, idealizaram a metodologia e batizaram-na de Estratégias Evolucionárias, para resolver problemas técnicos de otimização de perfis aerodinâmicos. Hoje, após diversas modificações, a sistemática é empregada em muitos problemas de otimização com variáveis reais, pois necessita de pouca informação sobre o problema, não incorrendo em derivadas da função a otimizar, e sendo aplicável a modelos tanto lineares como não lineares [BÄC 93].

Os primeiros algoritmos construídos utilizavam uma política conhecida como *(1+1)*, em que apenas os operadores de seleção e mutação eram utilizados e *um pai originava um filho* a cada geração. A mutação sofrida pelos indivíduos obedecia à distribuição normal. Posteriormente este processo foi ampliado, por Schwefel [BÄC 93], para estratégias “mais globais” denominadas $(\mu + \lambda)$. Uma nova proposta, a (μ, λ) , - dita μ vírgula λ - com μ pais e λ filhos, e também incorporando o operador de recombinação: Nesta proposta um novo indivíduo poderia ser formado potencialmente herdando características de todos os progenitores existentes na população.

Na forma $(\mu + \lambda)$ eram selecionados apenas os melhores indivíduos encontrados no conjunto união dos pais e dos filhos, indicando um caráter altamente elitista e, segundo Schwefel, inapta para operar em ambientes mutantes [BÄC 93], o que o leva a recomendar a estratégia (μ, λ) , em que os pais são eliminados antes da seleção, isto é, não convivem e não concorrem com os filhos. Frise-se que este traço não é o que ocorre mais amiúde nos fenômenos biológicos.

Uma característica importante da metodologia é que a seleção é feita sempre de forma determinística, ficando vivo o subconjunto dos melhores indivíduos, sem qualquer possibilidade de um elemento “menos agraciado” sobreviver. Schwefel [SCH 87], recomenda a estratégia (μ, λ) , com a sincronização entre o nascimento dos filhos e a morte dos pais. Em [BÄC 93] cita-se que as mutações não podem ser completamente randômicas, o que implicaria serem os filhos totalmente independentes dos pais e na Estratégia Evolucionária este é o operador de maior importância. A população deve ter tamanho adequado para proporcionar suficiente riqueza genética, o que previne o empobrecimento a cada geração; também deve haver cooperação entre os indivíduos, pois não se pode esperar que apenas o melhor concentre todo o conhecimento. Ainda mais, o processo deve permitir que haja deterioração em algum ponto, à semelhança do que faz a “têmpera simulada” (4.1.1), pois isto significa a possibilidade de escapar de um ótimo local e prosseguir no encalço do ótimo global da superfície de busca.

Os embasamentos teóricos da metodologia foram propostos por Rechenberg [REC 73], Schwefel [SCH 87] e Rudolph [RUD 92], tendo este demonstrado analiticamente que a metodologia $(1+1)$ converge. Este processo dedutivo pode ser adaptado para mostrar que a sucedânea $(\mu + \lambda)$ também converge, mas não se tem uma demonstração formalizada para a política (μ, λ) [BÄC 93].

4.4 PROGRAMAÇÃO EVOLUCIONÁRIA

Lawrence J. Fogel já pesquisava a aplicação de técnicas evolucionárias desde 1962, como demonstram suas publicações datadas deste ano e de seguintes [FOG 62, FOG 63, FOG 64].

Um ano após a publicação de Rechenberg [REC 65], divulgando a metodologia das Estratégias Evolucionárias, os pesquisadores L. J. Fogel, A.J. Owens e M.J. Walsh [FOG 66] lançaram seu livro, descrevendo o paradigma da Programação Evolucionária. Com outro ferramental de desenvolvimento, mas ainda baseado na inspiração evolucionista darwiniana, este grupo pesquisava nos EUA o que outro, independentemente, também procurava fazer em Berlin. O problema inicialmente tratado nesta metodologia era o de evoluir máquinas de estado finito para predição de símbolos. A aptidão de cada máquina era medida pelo número de símbolos corretamente previsto pela mesma, sendo que cada genitor originava, por mutação, um descendente. Dentre os ascendentes e descendentes, os melhores 50% eram escolhidos para continuar o processo, na próxima iteração. Esta, aliás, é a política $(\mu + \lambda)$ das Estratégias Evolucionárias.

Mais tarde, Daniel B. Fogel, filho de Lawrence, generalizou a metodologia, tornando-a aplicável a funções de variáveis reais, além de ter publicado o que consiste na atual fundamentação teórica do processo [FOG 92].

Deve-se notar que a Programação Evolucionária não usa recombinação de diferentes indivíduos progenitores para formação de prole, como em Estratégia Evolucionária e AG. Os criadores da metodologia argumentam que a recombinação não é usada porque a Programação Evolucionária se inspira na evolução inter-espécies, onde não existe cruzamento, e consequentemente, recombinação ([BÄC 93]).

Outra singularidade: em AG o problema é, em grande parte das aplicações, codificado em cadeia de caracteres que mimetizam as variáveis sob pesquisa, enquanto em Programação Evolucionária a representação dos indivíduos é função do caso sob análise. Assim, o único operador evolucionário, a mutação, na Programação Evolucionária, possibilita que pequenas variações no comportamento dos filhos ocorram de forma muito mais freqüente que grandes variações e é o único operador genético considerado. Uma população de 2μ indivíduos é formada a partir de μ pais e μ filhos, cada um deles advindo da mutação de seu pai. É feito um torneio estocástico, em que cada pai e cada filho, concorre com um subgrupo aleatório da população de pais e filhos. Os melhores μ indivíduos ranqueados no torneio sobrevivem, para formar a nova população.

Como fundamentação teórica, além da citada na obra de D. B. Fogel, pode-se dizer que Bäck & Schwefel ([BÄC 93]) afirmam ser a convergência da Programação

Evolucionária demonstrável, aplicando a mesma sistemática adotada para o caso $(1+1)$ das Estratégias Evolucionárias.

O campo de aplicação desta metodologia é especialmente aquele em que a superfície de solução da função de aptidão é muito acidentada, com muitos pontos de ótimo locais. Se assume que esta superfície de solução pode ser descrita em função de variáveis reais e tenha soluções ótimas, que podem ser atingidas com os passos gerais da metodologia:

- Escolher randomicamente uma população inicial de soluções experimentais;
- De cada indivíduo da população inicial gerar nova população, sendo seus componentes mutações do indivíduo original, e variando de um para outro continuamente, em um intervalo definido ;
- Calcular a aptidão de cada indivíduo, e, via torneio estocástico (podendo também ser determinístico, segundo o caso), classificar os indivíduos que comporão a próxima geração. O número de indivíduos pode variar de geração a geração.

Note-se que a Programação Evolucionária e as Estratégias Evolucionárias, apesar de terem nascido de forma independente, se assemelham por três aspectos principais:

1. Trabalham com os próprios valores das variáveis - em lugar de suas codificações, como no AG;
2. Usam mutação com o mesmo método Gaussiano (multivariado com média zero);
3. Adotam seleção entre pais e filhos para formar nova população (no caso da política $(\mu + \lambda)$). Por outro lado as diferenças mais marcantes são:
 - (a) A Programação Evolucionária seleciona aleatoriamente em um torneio, promovido entre os indivíduos da próxima população;
 - (b) Cada nova solução compete com certo número de oponentes e permanece na população em função de sua performance;
 - (c) Em contrapartida, em Estratégias Evolucionárias, usa-se seleção determinística, simplesmente descartando os piores indivíduos.

Estas duas metodologias, por trabalharem com os valores reais das funções a otimizar e se apoiarem sobretudo no operador de mutação, formam um todo à parte bastante diferenciado, com relação à sistemática dos Algoritmos Genéticos, que se passará a ver.

4.5 ALGORITMOS GENÉTICOS

Dos paradigmas de Computação Evolucionária, este é sem dúvida o mais largamente conhecido e empregado, além de ser o que mais pesquisas tem provocado [TAN 95].

Talvez este interesse se explique por ser sua aplicação a problemas concretos relativamente fácil, embora demande às vezes mais trabalho de codificação. Este é, aliás, um dos pontos cruciais do processo ([TAN 95], [MIT 96]), uma vez que, em Estratégias Evolucionárias e em Programação Evolucionária, os valores trabalhados são os próprios valores das funções a otimizar [BÄC 93].

Sintomaticamente, dos três paradigmas “fundamentais” da Computação Evolucionária, os AG formam a estratégia mais biologicamente inspirada, por simular mais fielmente o processo evolucionário, muito embora tenha inúmeros pontos em que se distancia muito da Natureza, como se procurará mostrar neste Capítulo.

Os AG foram desenvolvidos a partir dos trabalhos de pesquisa de John Holland, que, desde o início da última década de 60, esteve preocupado com o estudo da formalização de processos adaptativos da Natureza, simulando sistemas que recebiam informações sensoriais do meio ambiente através de detectores binomiais [HOL 62], [HOL 75]. Note-se que a motivação inicial dos pesquisadores não era então de otimização de sistemas nem a solução de problemas específicos. Entretanto, no livro em que formalizou o paradigma [HOL 75], Holland salientou sua aplicabilidade a problemas de economia, jogos, reconhecimento de padrões e otimização de parâmetros. K. de Jong [JON 75] estendeu e aprofundou a técnica para o uso específico da otimização.

4.5.1 Algoritmo Genético Canônico

O *Algoritmo Genético* historicamente proposto por J. Holland, o que a bibliografia especializada cognominou *Algoritmo Genético Simples*, ou *Algoritmo Genético Padrão*, ou *Algoritmo Genético Canônico* é bastante diferente dos processos hoje reconhecidos como sendo *Algoritmos Genéticos*. Foram englobadas, ao longo destes anos de pesquisa, inúmeras características com vistas a torná-lo mais robusto, mais eficiente, geral, etc., restando do *Algoritmo Genético* original a estrutura geral e as idéias básicas.

A Figura 4.4 fornece uma visão geral dos passos constitutivos do Algoritmo Genético Canônico, que, a grosso modo, constituem a tradução em simbologia de fluxograma, dos passos do algoritmo genérico formalizado por Bäck e Schwefel (em 4.2.2) para Computação Evolucionária.

FLUXOGRAMA DO ALGORITMO GENÉTICO CANÔNICO

No Algoritmo Genético Canônico, a mutação era aplicada com probabilidade muito baixa e constava da inversão de bits dos cromossomos filhos. A tendência de dar pouco peso ao operador mutação, geralmente permanece nos AG [TAN 95]. A recombinação é conhecida como “crossover” neste modelo e consiste no seccionamento, em algum ponto, da cadeia genética dos dois progenitores aleatoriamente escolhidos e na posterior permutação dos pedaços obtidos, formando os filhos. A seleção dos indivíduos que comporão a próxima geração é feita com regra de sobrevivência probabilística, combi-

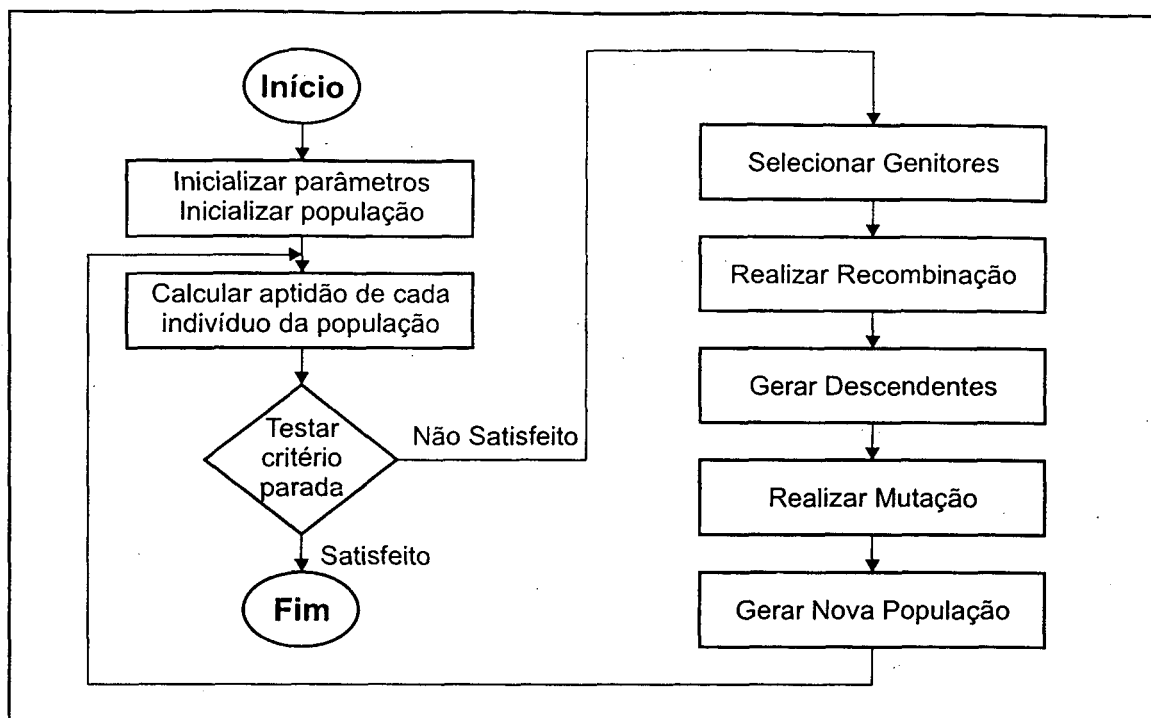


Figura 4.4: Passos gerais do Algoritmo Genético Canônico.

nada com os valores de aptidão, permitindo com elas que os genitores tenham maior ou menor prole.

FUNDAMENTOS TEÓRICOS

Os conceitos ainda hoje tidos como básicos na fundamentação teórica do processo desenvolvido pelos AG foram lançados por J. Holland na publicação [HOL 75]. Os temas lá desenvolvidos pormenorizadamente, tiveram como resultado principal o que hoje se reconhece como Teorema dos Esquemas ou Teorema Fundamental dos AG. Refazendo os passos principais da demonstração deste teorema, principia-se a seguir pelas definições dos conceitos envolvidos.

4.5.1.1 Notações e Definições

BLOCOS CONSTRUTIVOS (“buildings blocks”)

São subconjuntos de bits que supostamente conferem altos valores de aptidão nas cadeias em que aparecem [GOL 89].

ESQUEMA (“Schema”): H

Cadeia composta pelos caracteres 0, 1 (chamados bits definidos) ou * (chamado bit indefinido), formando como que um molde genérico, representativo de um conjunto de cadeias.

Exemplo: O esquema $H = 1 * 0 *$ representa todo o conjunto de cadeias:

1 0 0 0
1 1 0 0
1 0 0 1
1 1 0 1

Também se diz que um esquema define um hiperplano de dimensão igual ao l (número de bits ou comprimento da cadeia)[GUR 97].

ORDEM DE UM ESQUEMA: $O(H)$

É o número de bits definidos do esquema. No caso acima: $O(H) = 2$

COMPRIMENTO DE DEFINIÇÃO: $d(H)$

É a maior distância entre dois bits definidos do esquema. No caso acima: $d(H) = 2$

COMPRIMENTO DA CADEIA: $l(H)$

Número total de bits da cadeia, definidos e indefinidos. No caso acima: $l(H) = 4$

NOTAÇÕES

- (a) H : Esquema com no mínimo uma instância, isto é, uma ocorrência, na geração t , em análise;
- (b) $f(x)$ = aptidão da cadeia genérica x , na geração t ;
- (c) $\bar{f}(t)$ = aptidão média das cadeias (de toda a população), na geração t ;
- (d) $m(H, t)$ = número de instâncias do esquema H presentes na geração t ;
- (e) $\hat{\mu}(H, t)$ = média aritmética calculada dos graus de aptidão das instâncias de H na geração t .

O objetivo do desenvolvimento é, dado o número de ocorrências do esquema H na geração em análise no instante t , determinar qual será o número de ocorrências desta mesma cadeia na próxima geração, em consequência do processo adotado no Algoritmo Genético.

Em símbolos, deseja-se obter: $E(m(H, t+1))$ = número de instâncias de H na geração $t+1$

Tem-se, por definição:

$\frac{f(x)}{\bar{f}(t)}$ = número médio de descendentes de x (da geração t para a geração $t+1$), ou:

$$\hat{\mu}(H, t) = \frac{\sum_{x \in H} f(x)}{m(H, t)}$$

logo:

$$\sum_{x \in H} f(x) = m(H, t) \hat{\mu}(H, t)$$

Então:

$$E(m(H, t + 1)) = \frac{\sum_{x \in H} f(x)}{\bar{f}(t)} = \frac{\hat{\mu}(H, t)}{\bar{f}(t)} m(H, t)$$

Então na próxima geração, o número de esquemas H dependerá dos seguintes fatores da geração atual:

- a) relação das entre as médias dos graus de aptidão das instâncias do esquema H presentes e os valores das adaptações médias de todas as cadeias;
- b) do número destes esquemas H .

Entretanto, na próxima geração, os operadores de recombinação e de mutação influem neste número. Holland determinou esta influência, o que se mostra a seguir.

INFLUÊNCIA DA RECOMBINAÇÃO

Tanto a recombinação como a mutação têm efeito duplo: podem criar como destruir esquemas. Estudando a pior hipótese, isto é, o efeito destruidor, define-se:

p_c = probabilidade de que um esquema sofra recombinação, considerando aqui um único ponto de corte nos cromossomos constituintes das cadeias:

O esquema H terá sobrevivido a uma recombinação somente se um dos seus descendentes ainda contiver H . A probabilidade S_D de que um esquema seja destruído em uma recombinação é diretamente proporcional ao “comprimento do esquema” ($d(H)$) e inversamente proporcional ao “comprimento l da cadeia” em que está inserido, menos uma unidade ($l - 1$), pois o “ponto de corte” da recombinação (Ver 3.2.3) terá que ser feito necessariamente antes do último bit. Pode ocorrer ainda que, mesmo sofrendo recombinação o esquema não se desfça (por exemplo no caso em que duas cadeias idênticas se cruzam). Então o valor abaixo se trata de um limite de probabilidade máximo.

$$S_D(H) \leq p_c \frac{d(H)}{l - 1}$$

Logo, a probabilidade de sobrevivência do esquema, S_c , será o complemento desta probabilidade:

$$S_C(H) \geq 1 - p_c \frac{d(H)}{l - 1}$$

INFLUÊNCIA DA MUTAÇÃO

Seja:

p_m = probabilidade de mutação de um bit qualquer

então:

$1 - p_m$ = probabilidade de permanência de um bit qualquer

Como cada bit definido tem probabilidade de “mutar” independente dos demais, e a probabilidade de todo o esquema “não mutar”, $S_m(H)$, será exponencialmente menor, quanto maior for a ordem $O(H)$ deste esquema, se tem:

$$S_m(H) = (1 - p_m)^{O(H)}$$

e se chega à fórmula do propalado *Teorema Fundamental dos Algoritmos Genéticos*:

$$E(m(H, t + 1)) \geq \frac{\hat{\mu}(H, t)}{\bar{f}(t)} m(H, t) (1 - p_c \frac{d(H)}{l - 1}) (1 - p_m)^{O(H)} \quad (4.1)$$

Algumas suposições básicas para que o teorema seja válido [BEA 93]:

- (a) População tenha tamanho infinito;
- (b) A função de aptidão espelhe fielmente a utilidade de uma solução;
- (c) Os genes de um cromossomo não interajam significativamente.

Ora, a experiência que se tem visto nos AG, é que as populações oscilam geralmente no intervalo de 50 a 200 indivíduos, pois populações muito grandes tornam a aplicação da metodologia computacionalmente problemática. Estes números, mesmo que aumentados em várias ordens de grandeza, estão longe de serem consideráveis. O primeiro postulado acima advém do fato de que a teoria evolucionista darwiniana se apoiar principalmente no pilar hipotético: “dada a grande variabilidade das espécies...” [DAR 59]. Em populações pequenas, como as que os AG geralmente usam, pode ocorrer facilmente o fenômeno conhecido pelos biólogos como deriva genética (“genetic drift”), onde, devido a mudanças no ambiente, se perde um gene de baixa frequência relativa.

Por exemplo, se um fator (gene) está presente em 4% dos indivíduos, em 1.000.000 ter-se-ia 40.000 elementos com o fator. Alternativamente, se a população tem 100 seres, apenas 4 apresentarão a característica em causa. Morrendo os 4 ela é definitivamente perdida.

Quanto ao segundo postulado, a construção das funções de aptidão é, às vezes, “puro exercício de ‘achismo’” que procura uma forma matemática para dar a cada indivíduo da população uma “medida de qualidade” comparativa, para a solução do problema em questão. Se espera desta função que, para cada genótipo, ela produza um valor que possa ser comparado com outros, isto é, que mapeie os genótipos em um conjunto completamente ordenado [FAL 01a] (Ver 2.4.4).

A exigência de baixa relação entre os genes dos cromossomos não é absolutamente o que acontece na Natureza, onde é raro uma ligação biunívoca “pura” entre genes e suas manifestações fenotípicas. De fato, são comuns os fenômenos da *pleiotropia*, onde um gene influencia várias características físicas, e seu inverso, a *poligenia*, onde é necessária a conjugação de vários genes para que um determinado traço fenotípico emergja.

Talvez também seja oportuno lembrar que os achados do Projeto Genoma [BIS 90] estão mostrando que a idéia de que os genes sejam os “quanta” definitivos nas construções fenotípicas deve ser vista com mais cuidado, dando-se mais importância ao papel das proteínas, enzimas, etc.

OBSERVAÇÕES

- (a) Este teorema descreve o crescimento de um esquema de uma geração a outra e diz que esquemas curtos e de ordem baixa (l e O baixos), cujos valores de aptidão médios ficam acima da média aritmética das demais cadeias de uma geração, receberão número de amostras exponencialmente crescentes: o número de “esquemas úteis” que evitam a ruptura, permanecendo com aptidão acima da média, cresce na proporção de $\hat{\mu}(H, t)/\bar{f}(t)$ a cada geração.
- (b) A expressão 4.5.1.1 fornece o limite inferior do número esperado de instâncias do esquema em análise em cada geração, pois só leva em consideração o efeito maléfico da mutação e do cruzamento. Entretanto o cruzamento também poderia ter a possibilidade de recombinar bons esquemas e formar outros de ordem maior, iguais ou ainda melhores. A literatura especializada tem chamado de *Hipótese dos Blocos Construtivos* a este estudo [GOL 89].

Segundo Holland [HOL 75] o AG tem a virtude de explorar a superfície de solução tanto em *extensão* (“explore”, em Inglês), quanto em *profundidade* (“exploit”, em Inglês). O AG procuraria em todas as áreas desta superfície (extensão), e simultaneamente alocaria mais recursos de pesquisa nas que são mais promissoras, pesquisando-as em profundidade. Este balanço é conseguido em função dos operadores de recombinação, que dá mais ênfase aos indivíduos mais promissores (“exploits”) e de mutação, que permite a varredura em todas as regiões da superfície de busca. Com este operador sendo superior a zero, todo indivíduo da população teria alguma probabilidade de ser selecionado.

Uma sistemática que dê muita ênfase às buscas em diferentes áreas torna-se, no limite, num algoritmo de busca randômica, enquanto outra, que se concentre mais profundamente em uma área, tende para o protótipo da “Escalada de Encosta”. Há trabalhos, contudo, mostrando que o AG é bastante robusto quanto a variações dos valores dos operadores de mutação e de recombinação, havendo maior sensibilidade em relação à função de aptidão e à codificação utilizada [GRE 86].

- (c) Apesar de se falar somente em esquemas, estas considerações também valem para qualquer subconjunto de cadeias do espaço de soluções e o foco em esquemas apenas se deve ao fato de eles supostamente serem responsáveis pela formação de bons “blocos construtivos”. Entretanto, como diz Mitchell [MIT 96]: “A teoria dos Algoritmos Genéticos não é de modo algum um livro fechado. Na realidade, há mais questões abertas que resolvidas”.

Trabalhando com cadeias de alfabeto binário, ter-se-ia 2^l possíveis cadeias de comprimento l . Cadeias de comprimento qualquer seriam em número muito

maior [MIT 96]. Holland faz uma analogia do funcionamento do Algoritmo Genético Canônico com uma hipotética máquina caça níqueis de duas alavancas ⁵. Conclui que o AG Canônico implementa a política de alocar os melhores esquemas - geralmente os mais curtos - com um número de escolhas que cresce exponencialmente, mas no máximo este número atingiria 3^l .

Esta “virtude” do AG é conhecida como “*paralelismo implícito*”, enfatizando a idéia de que o processo seguido pelo AG automaticamente procura vários pontos do espaço de solução de forma paralela, simultânea. Entretanto, em trabalho mais recente [GRE 91], Holland admite outra interpretação, em que o AG implementa um modelo onde o espaço de soluções é dividido em partições. Isto mais uma vez vem demonstrar a distância que separa o rigorismo matemático das formalizações existentes em Computação Evolucionária: ainda não há um conjunto de teoremas que explique de forma completa muitos dos resultados conseguidos.

- (d) Através do seu Teorema Fundamental dos AG, Holland mostra que o AG, alocando, ao longo do tempo, cada vez mais testes aos melhores esquemas encontrados, convergirá para pontos de ótimo. Beasley [BEA 93], apoiando-se nos trabalhos de De Jong [JON 75], diz que: “Se o AG foi corretamente implementado, a ‘população evoluirá’ através de gerações sucessivas, de forma que o grau de aptidão do melhor indivíduo de cada geração, bem como a dos médios, aumenta em direção a um ótimo global. Entenda-se convergência como a progressão para uma uniformidade crescente.

Pode-se dizer que uma população convergiu para um esquema [MIT 96] quando grande parte dos seus elementos são instâncias deste esquema.

A função de aptidão deve refletir o valor real dos cromossomos, o que às vezes não é simples de se conseguir, pois em um processo físico, como o cálculo da trajetória balística de um projétil se sabe *o quê computar*. Num outro caso, por exemplo, na construção de horários de plantões hospitalares de um conjunto de médicos, apesar se conhecer quando as soluções são inviáveis (como quando um médico é alocado em dois locais diferentes simultaneamente), não se sabe como construir uma função geral que retrate com precisão a qualidade das soluções possíveis [BEA 93], [KOM 00].

PROBLEMAS

A literatura da área tem muitos casos em que o AG não funciona ([MIT 96], [JON 93]) e alguns autores têm adotado, nestes casos, a política alternativa de apenas usá-lo para determinar soluções satisfatórias, em lugar de soluções ótimas. Métodos híbridos, usando inicialmente AG, seguidos de *escalada de encosta*, *gradiente* [HAR 95] ou de *têmpera simulada* [MAZ 99] têm sido a estratégia sugerida.

A relevância da análise dos esquemas em AG é posta em dúvida por muitos

⁵Conhecida, por semelhança, como: “Two armed bandit” - (As usadas em cassinos são chamadas jocosa-mente de “bandidos de um só braço, manetas”).

pesquisadores da área ([MAS 93], [PEC 93], [TAN 95]), baseando-se sobretudo nas hipóteses muito restritivas que formam os postulados da demonstração de Holland. De fato, alguns pontos críticos não têm aplicação natural nem eficaz [MIC 92], em muitos casos. Entre outros, cita-se:

- Alfabeto binário adotado na demonstração;
- Suposição de população infinita;
- Haploidia cromossômica (Ver conceito à página 104);
- Aplicação problemática dos operadores de seleção, mutação e recombinação.

Tanomaru ([TAN 95]) conclui textualmente: “Consequentemente, acredito que os os esquemas não mereçam o destaque que têm recebido na literatura, e sejam mais um exercício fútil de matemática do que algo que venha realmente a iluminar o poder de processamento dos AGs”.

Finalizando, apesar de todas estas “fraquezas teóricas”, na prática o AG tem funcionado, às vezes mesmo espantosamente bem, o que leva o mesmo autor a lembrar com oportunidade definição jocosa “teoria é quando se sabe tudo e nada funciona e prática é quando tudo funciona e nada se sabe”.

4.6 PROGRAMAÇÃO GENÉTICA

No seu trabalho de 1992, John Koza [KOZ 92] cunhou a expressão “Programação Genética”, para seu método de geração automática de programas. Este método, a partir de uma população inicial de programas, procura evoluir outros que, quando executados supostamente devem resolver o problema em causa. Geralmente eles são expressos via representação de uma árvore sintática, e não por linhas de código, como os construídos em linguagens declarativas. Sendo a Linguagem LISP bem adaptada para representar as estruturas de árvores e para implementar a modelagem dos operadores de mutação e recombinação, é a mais utilizada neste paradigma de Computação Evolucionária.

Um exemplo de um cromossomo, ou de um programa, seria:
 $(\text{sqrt}(*A(*AA)))$, significando $A^{3/2}$.

A é denominado *terminal*; *sqrt* e $*$ são funções de um e dois argumentos, respectivamente;

Um fluxograma de um algoritmo de Programação Genética, conforme modelagem proposta por Koza, teria a forma geral dada na Figura 4.5, construída conforme [MIT 96].

O operador mais diretamente empregado no modelo de Koza é o de recombinação. Os cromossomos são as próprias árvores e trechos delas são permutados. Mitchell [MIT 96] assume que o operador de mutação “pode ser implementado, escolhendo-se um ponto randômico da árvore e substituindo a sub-árvore abaixo deste ponto por outra sub-árvore gerada randomicamente”.

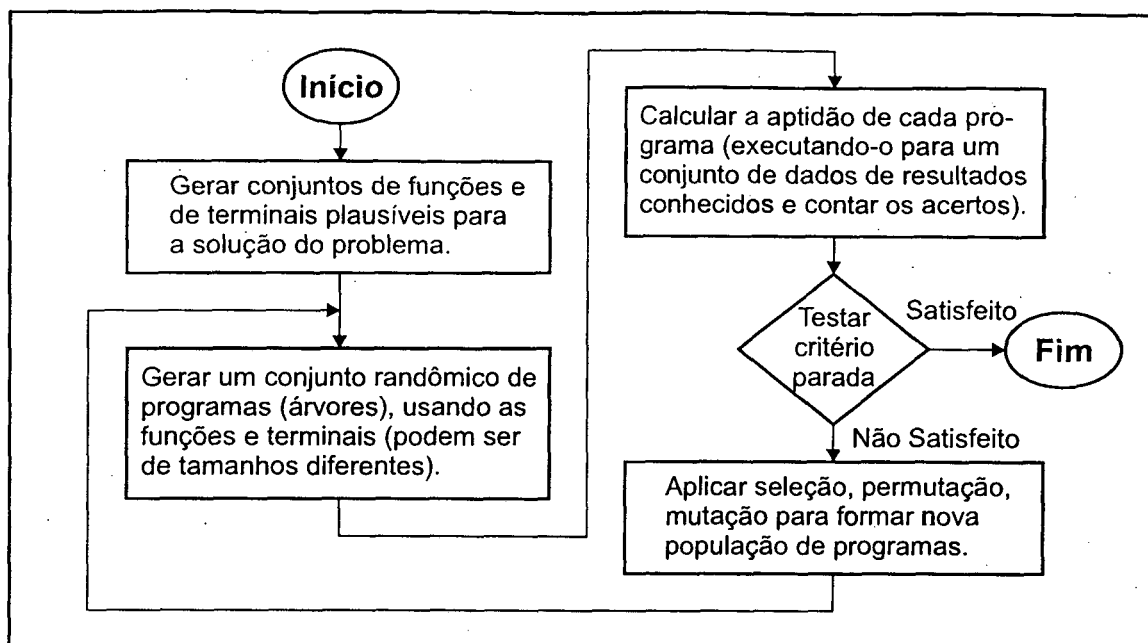


Figura 4.5: Fluxograma de um Algoritmo de PG, conforme Koza.

Uma consequência interessante desta representação e da aplicação dos operadores é que os cromossomos, isto é, as árvores, mudam de comprimento ao longo do processo, sem muito trabalho de controle ou de programação adicional, o que nos Algoritmos Genéticos, só é conseguido com mais esforço.

A geração automática de programas seria uma ferramenta particularmente interessante para computadores paralelos, onde a própria construção de programas é um obstáculo a seu uso. Entretanto a Programação Genética tem sido testada apenas em programas relativamente simples. A questão de que tal técnica seja factível para outros, de estrutura mais complexa [O'R 94], está em aberto. Há colocações de que o sucesso nos casos demonstrados por Koza seja talvez devido principalmente à facilidade do LISP em tratar problemas descritos por listas [MIT 96].

As aplicações existentes em Programação Genética se relacionam com as áreas de planejamento, compressão de imagens, robótica e controle.

A metodologia utilizada em Programação Genética pode ser encarada como um caso particular de Algoritmos Genéticos, o que pode ser um motivo para alguns autores como [MIT 96] e [BÄC 93] a não citarem entre os paradigmas de Computação Evolucionária.

4.7 SISTEMAS CLASSIFICADORES

A expressão "*Sistemas Classificadores*", bem como seu desenvolvimento inicial, foi mais uma contribuição de John Holland, trazida no seu trabalho com Reitman [HOL 78]. Posteriormente este autor agregou o termo "aprendizado" a ela [BOO 89] e hoje se aceita que o assunto esteja incluído no paradigma de aprendizado chamado "*Aprendizado Evolucionário*".

Reforçado". Em poucas palavras, consiste em um sistema de aprendizado por máquina (automático), com propriedades de aprendizado de regras sintáticas, usado em ambientes de otimização. Frise-se que, neste caso, um *software* que tem comportamento simulando o aprendizado, é conhecido como um "*sistema de aprendizado por máquina*".

A metodologia imaginada por Holland permitia a classificação das atividades do ambiente e o indivíduo reagia a elas de forma apropriada, aprendendo no processo.

O sistema sugerido é composto de:

- a) um ambiente, artificialmente criado em um mundo digital;
- b) detectores para captar as entradas vindas do ambiente;
- c) atuadores para possibilitar a manipulação do ambiente e adaptar-se a ele.

Agindo de forma similar a um sistema de controle, que usa retroação para adaptar (controlar) os atuadores, os Sistemas Classificadores usam a retroação para "ensinar" (adaptar) as regras que o compõem.

Em Sistemas Classificadores, é criada uma população, geralmente randômica, de regras "*if then*" - cada uma delas é chamada regra classificadora. Usando AG, o Sistema Classificador aprende que regras aplicar em um dado ambiente [GOL 89]. As entradas são comparadas com as regras classificadoras, que disparam os atuadores adequados.

O Sistema Classificador opera inicialmente "*no modo aprendizado*", e posteriormente, quando há suficiente conhecimento armazenado, passa ao "*modo de aplicação*". A Figura 4.6 indica que, no "*modo de aplicação*", a linha representativa da retroação é eliminada.

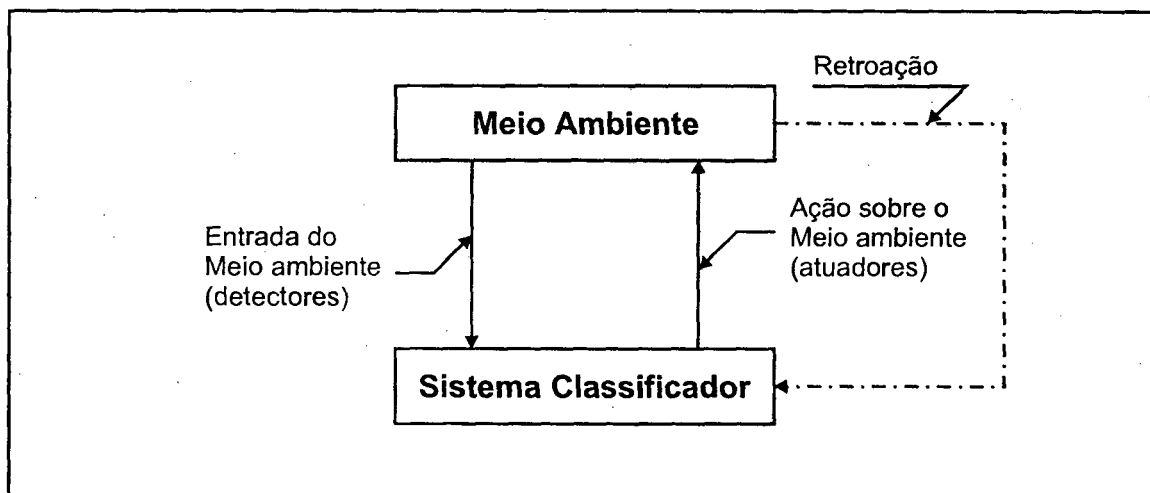


Figura 4.6: Os dois modos de trabalho de um Sistema Classificador.

Um problema dos SC é que as regras (fatos observados ou 'sugestões' de conhecedores) são coletadas como nos SE de IAS (através de entrevistas com especialistas, em literatura, etc.), formando um conjunto estático e podendo ocasionar conflitos, se mais de uma regra for aplicável em uma situação, ou mesmo nunca seja aplicável, o que o sistema também não detecta [RIO 88].

Nos Sistemas Classificadores com “*Aprendizado Reforçado*”, cada regra classificadora incorpora um parâmetro adicional, modificável em resposta à experiência: daí o nome *Aprendizado Evolucionário Reforçado*, isto é, fortalecido pelas informações advindas do ambiente.

A capacidade de aprendizado é uma virtude importante dos Sistemas Classificadores e é uma potencialidade a ser explorada nos SE tradicionais.

Alguns exemplos em que já foram usados Sistemas Classificadores são sistemas de controle de deslocamento para robôs e plantas de controle de redes de distribuição de gás, em escala nacional. Entretanto D. E. Goldberg ([GOL 92]) diz textualmente: “Sistemas Classificadores são um pântano, ... um magnífico, extraordinário e criativo pântano, mas ainda um pântano”.

4.8 COMPARATIVO ENTRE PARADIGMAS DE COMPUTAÇÃO EVOLUCIONÁRIA

A Tabela 4.3 abaixo, inspirada em [BÄC 93] e [BÄC 96] traça um paralelo entre os três principais paradigmas de Computação Evolucionária. É importante que se diga: Esta tabela foi montada levando em conta sobretudo os resultados da aplicação em casos de otimização de funções algébricas ou transcendentais bem específicas. Consequentemente a generalização das informações nela contidas deve ser feita cuidadosamente, sobretudo para outras situações de otimização.

A codificação dos indivíduos é indicada como feita com valores binários em AG e com valores reais nos outros dois paradigmas. Esta constatação é válida no caso de adoção do AG Canônico, mas deve-se ter em mente que o problema de qual codificação adotar, juntamente com o da construção de funções de aptidão adequadas, são enfaticamente apontados como das mais importantes e difíceis decisões na aplicação dos AG ([MIT 96], [TAN 95]). Este último autor reitera que em muitos casos a adoção do alfabeto binário não é natural nem eficiente, uma das razões pelas quais não dá grande importância ao teorema de Holland.

Schwefel [SCH 87] criou um “mecanismo especial de mutação que permite ao algoritmo evoluir seus próprios parâmetros estratégicos (desvio padrão e covariância)” e denominou auto-adaptação a esta sistemática, que é propriamente definível apenas para os paradigmas de Estratégias Evolucionárias e Programação Evolucionária.

Quanto à função de aptidão, os autores chamam de “valor normalizado” o resultado obtido com o trabalho que às vezes se faz de mudança de escala para, por exemplo, torná-lo positivo.

A teoria disponível para estes paradigmas aponta sua convergência em casos bem definidos, sumariamente explicitados na tabela e comentados anteriormente.

O operador de seleção é denominado extingível (na Tabela 4.3) quando alguns indivíduos têm probabilidade zero de serem escolhidos para reprodução, enquanto

Tabela 4.3: Comparativo entre Estratégias Evolucionárias, Programação Evolucionária e AG.

	<i>Estratégia Evolucionária</i>	<i>Programação Evolucionária</i>	<i>Algoritmos Genéticos</i>
Representação	Valores reais	Valores reais	Valores binários
Auto-adaptação	Desvio padrão e covariância	Variância	Não há
População	Constante	Constante ou Variável	Constante, geralmente
Publicações disponíveis	Médio	Baixo	Alto
Aptidão	Valor da função objetivo	Valor normalizado da função Objetivo	Valor normalizado da função objetivo
Inspiração Biológica	Média	Menor	Maior
Mutação	Operador principal	Único operador	Operador secundário
Recombinação	Importante p/ Auto-Adaptação	Não há	Operador principal
Seleção	Determinística	Probabilística Extinguível	Probabilística Preservativa Extinguível
Restrições	Restrições, inequações e arbitrário	Não há	Limites simples, providos pelo mecanismo de codificação
Teoria	Taxa de convergência para casos especiais: $(1 + 1) - EE$, $(1 + \lambda) - EE$, $(1, \lambda) - EE$, convergência global para $(1 + \lambda) - EE$	Taxa de convergência para casos especiais: $(1 + 1) - PE$; convergência global para $(1 + 1) - PE$	Teoria do processamento de esquemas, convergência global para a versão elitista

na preservativa todos têm este valor superior a zero. No caso do AG Canônico, o operador mutação superior a zero garante esta propriedade.

4.9 PARADIGMAS DA COMPUTAÇÃO EVOLUCIONÁRIA E A INSPIRAÇÃO NA NATUREZA

Os modelos baseados na Natureza foram grandemente simplificados ou adaptados para se constituírem em algoritmos de fato implementáveis ou mais efetivos, baratos, etc. em máquinas digitais. Assim Barreto [BAR 01] diz que “Em alguns casos, devido ao fato dos pioneiros não se sentirem obrigados a imitar a Natureza, copiaram apenas aspectos que lhes pareceram convenientes, na tarefa de resolver problemas. Além disto algumas vezes a introdução de mecanismos não usados pela Natureza foram adotados a título de melhorar a obra da Natureza”. E em seguida cita vários pontos onde a Computação Evolucionária não “seguiu a cartilha da Natureza”, dos quais são aqui destacados alguns:

- Os algoritmos evolucionários estressam o papel do genótipo, permanecendo o fenótipo, que na realidade muito influi, sem nenhuma tarefa na Computação Evolucionária;
- Na Computação Evolucionária, dá-se à recombinação e à mutação mais peso que a realidade biológica em geral mostra [BÄC 93];
- Mutações individuais de efeito nulo na população são comuns na Natureza (casos em que o indivíduo mutante não gera descendentes), o que não ocorre na Computação Evolucionária;
- Os progenitores não convivem com a prole, o que raramente ocorre na Natureza e muito influi na evolução [GAR 94];
- Na Computação Evolucionária, geralmente a prole nasce uma única vez, no fim de cada ciclo, o que é grande simplificação da Natureza.

Bäck & Schwefel [BÄC 93] reconhecem que o esquema de evolução adotado pelos AG é ligeiramente mais próximo ao modelo natural que os outros dois paradigmas por eles reconhecidos: a Programação Evolucionária e a Estratégia Evolucionária, mas dizem que “o código genético e o mecanismo epigenético têm sido completamente ignorados, até agora”.

Além das assimetrias apontadas na Bibliografia acima listada, cita-se ainda outros pontos discordantes, entre os paradigmas de Computação Evolucionária e os processos da Natureza de onde derivam, que poderiam ser explorados para testar se seriam facilmente simuláveis e eficientes como solucionadores de problemas:

1. SIMPLIFICAÇÕES FORÇADAS

Na Natureza os sistemas são interconectados, trabalham em harmonia em cada um dos seres que colaboram para constituir, enquanto na ciência geralmente são isolados. Nos

modelos atuais os acasalamentos são apenas entre indivíduos escolhidos probabilisticamente, não se levando em consideração:

- O equilíbrio intra-espécie;
- O equilíbrio inter-espécies.

No caso de duas espécies competindo por um mesmo recurso, a solução exigiria o abandono da procura cega ao ótimo de cada uma delas - a vencedora aniquilaria a outra. Em alternativa, poder-se-ia implementar uma busca de um sub-ótimo de compromisso, aceitável por ambas.

Em [LEH 00] se desenvolve interessante trabalho, onde os indivíduos não interagem apenas randomicamente como na proposta do Algoritmo Genético, mas adotam estratégias de atuação em que os passos do processo evolutivo são dados seguindo regras adotadas em “teoria de jogos”. Este modelo é muito mais conforme o que a Natureza adota. Nela se observa amiúde que, mesmo indivíduos componentes das espécies biologicamente em escalas evolutivas inferiores, muitas vezes agem em conformidade com a atuação de seus pares e não em virtude do que lhes é indicado pela extração de um número aleatório.

Adicionalmente, quando se implementa um AG, não se trabalha com duas espécies simultaneamente. Existe uma espécie e tudo o mais é meio ambiente (não existem duas espécies competindo). Por exemplo, um AG que modele a reprodução de coelhos, os lobos que predam os coelhos são simulados no meio ambiente como um fator de risco ‘de predação aos coelhos’. Considera-se o meio ambiente imutável. No entanto isto não é verdade. De fato, se aumenta o número de coelhos, deve crescer também o de lobos, porque existindo mais comida para eles, é natural que se criem mais fortes e se reproduzam mais. Com o crescimento do número de lobos, cresce também a procura por coelhos que passam a ser mais escassos e assim, faltando comida para tantos lobos, é natural que decresça seu número. A componente ‘lobo’ do meio ambiente é fortemente afetada pela espécie ‘coelho’ a que aplicamos o modelo de AG. Entretanto, este fato dificilmente é modelado com propriedade realística neste paradigma.

2. ALEATORIEDADE E POPULAÇÕES INFINITAS

A ‘linha evolucionária’ supõe um ‘evoluir’ meramente aleatório, não levando em conta que muitas das vezes os indivíduos têm interesses próprios e adotam estratégias para consegui-los. Não é portanto meramente estocástico o seu comportamento, e sim o resultado de um jogo complexo [LEH 00] em que cada uma das partes age conforme regras às vezes não explicitadas, mas reais e determinantes nos resultados do problema em pauta. De qualquer forma, a aleatoriedade seria mais crível se as populações fossem de fato infinitas, o que é impraticável. Assim se tem na Natureza um jogo não propriamente aleatório. Também existem os efeitos das populações isoladas (ilhadas). Habitualmente os algoritmos não contemplam estas realidades, apesar de existir mode-

los em que se definem sub-populações da espécie ocupando diferentes nichos do meio ambiente.

3. INFLUÊNCIAS CULTURAIS E SOCIAIS

Os modelos computacionais priorizam, ou melhor, atêm-se apenas à evolução genética ‘fria’, ‘matemática’, ‘mecânica’ das espécies. Entretanto nota-se na natureza que certas sociedades [DOR 97] procedem como tendo memórias coletivas, culturais. Nelas, como na espécie humana, os valores socioculturais levados em conta para o acasalamento mudam com esta memória, com a cultura, com o meio ambiente (Ex. em certa época, mulheres gordas eram o ‘must’ de beleza - talvez porque demonstrassem, com sua opulência, serem mais sadias, mais bem alimentadas, mais ricas, melhores cozinheiras, etc.):

A passagem de conhecimento inter-gerações é um fato geralmente observado em espécies mais evoluídas. Este é outro fator pouco explorado nos paradigmas de CE.

4. MITOSE E MEIOSE

Com o aparecimento dos primeiros seres unicelulares, procariontes - sem núcleo organizado - surgiu a vida na terra há aproximadamente quatro bilhões de anos, mas os primeiros seres com núcleo, ainda unicelulares, são datados de um bilhão e meio de anos. Somente na era Cambriana, há uns seiscentos milhões de anos, surgiram os organismos multicelulares e ocorreu verdadeira explosão de ocorrência de novas espécies [LEW 84]. Portanto durante milhões e milhões de anos, a biologia ficou quase parada em termos do aparecimento de novas espécies. Geralmente estes seres eram assexuados, tendo no processo de divisão celular conhecido como mitose, sua forma de reprodução, o que ocasionava pouca variabilidade entre os indivíduos (ver em 3.2.2).

A especiação, isto é, a formação de novas espécies, acelerou-se acentuadamente, com a descoberta do sexo, porque a variabilidade biológica que se possibilita criar é muito maior que a permitida com o “crossover” e com a mutação, fenômenos de mais baixa frequência. Estes fatos sugerem que os algoritmos de CE levem mais em conta os processos naturais.

5. HAPLOIDIA

A maioria absoluta dos AG trabalha com indivíduos constituídos de cromossomos haplóides, isto é, com apenas uma cadeia de cromossomos, enquanto na Natureza a maioria dos seres mais desenvolvidos têm em suas células somáticas, cromossomos diplóides (constituídos por um par de cadeias ditas homólogas: cada gene tem como que um “back-up” no outro cromossomo). São haplóides apenas as células reprodutoras. Além disto, nestes seres, as células são formadas por um conjunto completo de cromossomos,

e não com cromossomos de um só tipo, como nos AG. Por exemplo o ser humano tem 23 diferentes pares de cromossomos nas células somáticas.

6. SOLUÇÕES MAIS “SIMPLES” ANTES

Como observado nas escalas filogenéticas, os seres mais “simples” geralmente aparecem antes na escala evolutiva, fato que poderia ser simulado nos modelos da CE.

Deve-se salientar que os trabalhos científicos, na área de Computação Evolucionária, parecem ser classificáveis em um dos itens:

- a) Relatos empregando determinado paradigma para um tipo específico de problema;
- b) Modificações sugeridas no algoritmo originalmente proposto, para torná-lo mais eficiente, geral, etc.;
- c) combinações de dois ou mais paradigmas para conseguir novas qualidades;
- d) Comparações entre diversos paradigmas na solução de um problema.

Dado que ainda se está longe de se ter solução para todos os problemas enfrentados, a busca de novas metodologias parece ser trabalho importante.

Até hoje, grande parte das metodologias usadas nas soluções de problemas históricos vieram da observação direta da Natureza. Ela, ao modo do desafio da Esfinge - “decifra-me ou te devoro”- propõe situações como o fogo, a água, o ar, a terra, as doenças, etc. e suas conseqüências, caso não sejam contornadas: sente frio, não veleja, não voa, não colhe, morre. Mas, a Natureza mostra soluções para os problemas que ela cria e até para alguns que ela não cria, o que a Esfinge não faz.

A história é pródiga em exemplos do que parece ser processo recorrente na criação de teorias ou metodologias de solução de problemas. Para citar apenas alguns casos ilustrativos, a lei da gravitação universal, da mecânica clássica de Newton, ocorreu-lhe com a folclórica observação da queda livre dos corpos (de uma maçã?). A teoria da relatividade foi possivelmente intuída por Einstein em uma estação ferroviária quando notou a importância do movimento relativo das máquinas entre si e dos transeuntes. Alexander Fleming descobriu a penicilina observando os efeitos do fungo *penicilium notatum* que acidentalmente contaminara uma cultura de bactérias tipo estafilococos, matando estes microorganismos. Darwin derivou sua teoria da evolução das espécies, conforme suas próprias palavras, “seguindo o exemplo de Charles Lyell em Geologia ... e recolhendo variações de animais domésticos e selvagens” [DAR 59].

Depois da constatação de que os processos mentais têm lugar no cérebro [SEA 84], é mandatório que se tente reproduzi-los para testar a possibilidade de se “construir a inteligência”. Ademais, depois de tantas vezes se ter visto o caminho feito com sucesso, é natural que novamente ele seja trilhado para se buscar uma solução inspirada na Natureza, quer seja em processos físicos, químicos ou biológicos, na procura de soluções de problemas, para os quais não se tenha ainda resposta disponível ou adequada.

Resumindo, o processo recorrente do que aqui se fala pode ser visto na Figura 4.7 [FAL 00]. Nesta, o “loop Natureza”, já foi tantas vezes utilizado com sucesso que seria um desperdício não copiar esta “invenção da roda”.

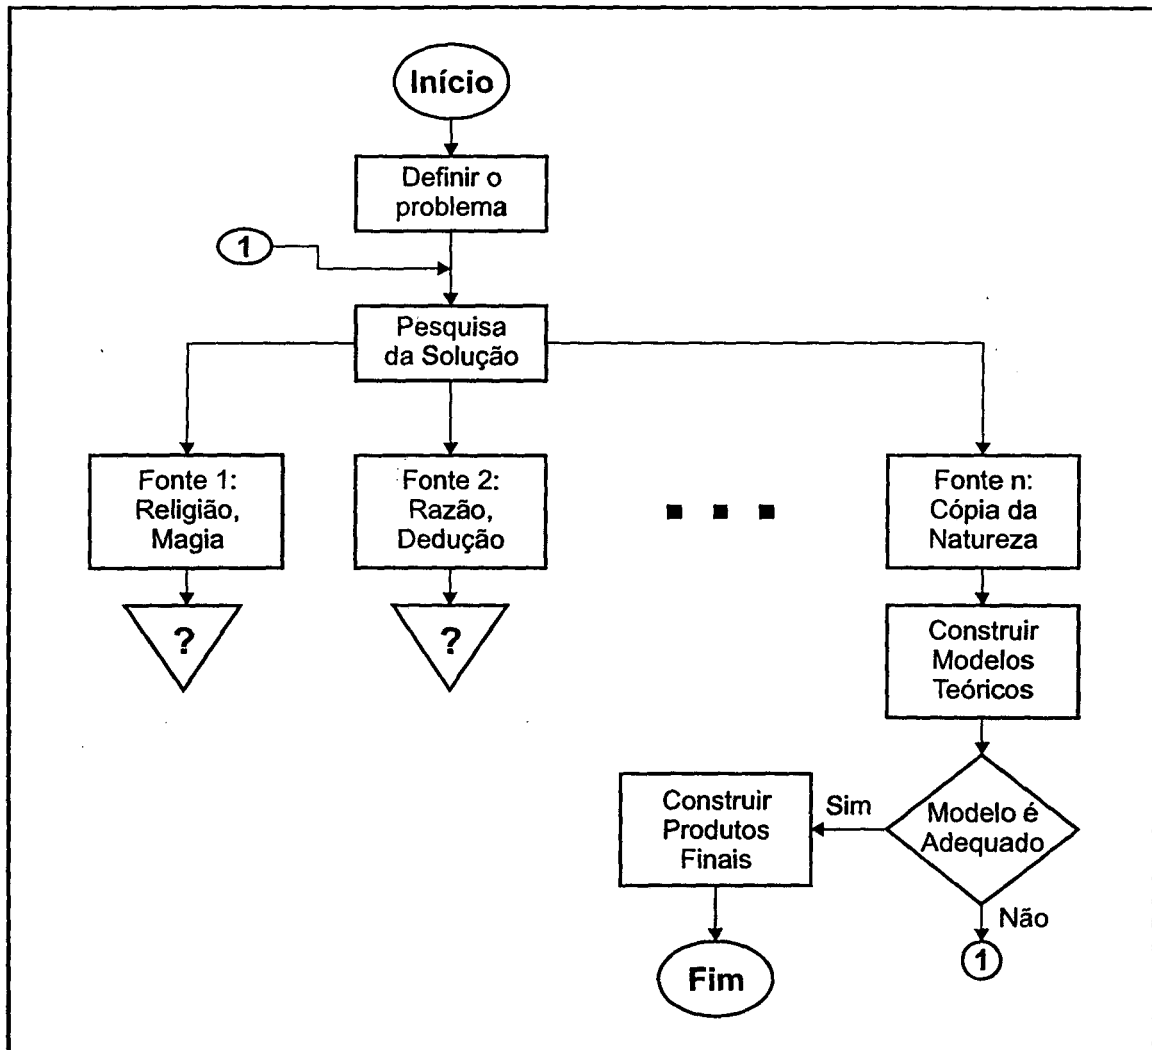


Figura 4.7: A Natureza como fonte de solução dos problemas humanos.

Na Figura a fonte “Natureza” tem sido das que mais soluções tem ofertado ao homem na área de estudo que este trabalho mais se atém: os paradigmas de Computação Evolucionária. Assim sendo é interessante retornar a cada paradigma e novamente verificar o que se tem aproveitado das “sugestões” da Natureza, para, possivelmente, incorporar aos algoritmos de soluções de problemas até agora propostos, as divergências entre os mesmos e as soluções naturais encontradas. Também uma busca mais minuciosa, visando o encontro de novos paradigmas, talvez adotados pela Natureza em áreas ainda não exploradas, e que pudessem ser simulados “in totum” ou modificados, para auxiliarem na área da Computação Natural, seria trabalho relevante.

A mesma Natureza em que o homem está inserido lhe traz, a um tempo, problemas e soluções muitas vezes superiores àquelas derivadas de uma busca puramente teórica. Diversas áreas, aqui globalmente denominadas de Computação Natural, têm trazido soluções promissoras para casos até então só parcialmente tratados ou totalmente insolúveis.

Neste Capítulo se procurou esboçar os cinco paradigmas mais sedimentados de Computação Evolucionária para, em seguida, mostrar que, seguindo novamente os passos já andados pelas metodologias, pode-se melhorá-las, copiando mais fielmente os processos naturais. Descobrir e simular outras metodologias de solução de problemas que a Natureza tem para oferecer poderia ser outro efeito colateral deste enfoque.

Uma simulação do aprendizado que gerações descendentes podem haurir das antecedentes será proposta no Capítulo 5. Procura-se assim testar a hipótese de que a convivência possibilitada pela assincronia entre início e fim de gerações adjacentes traga benefícios, pelo menos em certas circunstâncias.

Capítulo 5

EM BUSCA DE AG MAIS BIOLOGICAMENTE PLAUSÍVEL

“Ad augusta¹ per angusta” (Provérbio Latino)²

5.1 INTRODUÇÃO

Para testar a viabilidade prática da aplicação de métodos mais biologicamente inspirados, foram selecionados dois problemas. Nesta seleção adotou-se como principal diretiva a simplicidade do entendimento e da aplicação da metodologia, o que facilitaria o controle do processo, minimizando possíveis fatores complicativos advindos de itens com efeitos desconhecidos.

Adotando esta estratégia, o primeiro caso trabalhado foi o problema da busca de *Quadrados Mágicos* [BEN 76] de ordem 4 e o segundo o treinamento de Redes Neurais para diagnóstico médico em casos de complicações reumáticas. No primeiro caso foi proposta uma solução baseada na ferramenta AG padrão, com vários problemas e conclusões apontados. No segundo experimento, inicialmente o AG canônico foi proposto e posteriormente o mesmo algoritmo foi modificado, com o acréscimo da possibilidade de simulação de aprendizado entre indivíduos de populações contíguas.

¹Ada Augusta: Condessa de Lovelace, Filha de Lord Byron e auxiliar de C. Babbage, homenageada com a Linguagem ADA.

²À glória se chega através do sacrifício.

5.2 APLICAÇÃO DE AG AO PROBLEMA DO QUADRADO MÁGICO: ENSAIO

5.2.1 Conceitos preliminares

O Quadrado Mágico é definido como uma matriz quadrada, cujos elementos são inteiros sequenciais iniciados pela unidade, sem repetição, ocupando qualquer ordem nas células da matriz.

Assim a matriz quadrada de ordem (módulo) 3, cujos elementos vão de 1 a 9, sem repetição, formam o quadrado conhecido como *de módulo 3*. O de *módulo 4* tem elementos não repetidos, variando de 1 a 16, arranjados em matrizes de 4 linhas e 4 colunas.

Para serem *quadrados mágicos* estas matrizes devem obedecer a uma regra: as somas de cada linha, de cada coluna e de cada diagonal (principal e secundária) deve ser invariável e é denominada *constante do Quadrado Mágico* [TAH 86].

Esta constante pode ser facilmente calculada se considerarmos que os elementos do mesmo estão em uma Progressão Aritmética - PA - de razão 1. Então, no caso do Quadrado Mágico de módulo 4 teríamos os valores da PA de 1 a 16 distribuídos em 4 filas (4 linhas de 4 colunas cada). A soma S dos n dos termos desta PA valeria, em consequência:

$$S = \frac{(a_1 + a_n)n}{2} = \frac{(1 + 16)16}{2} = 136$$

Portando cada fila (linha ou coluna) teria em média, como valor da soma de seus elementos, um quarto do valor total, isto é, 34, que é a constante do Quadrado Mágico de módulo 4. De modo similar se encontraria 15 para a constante do Quadrado Mágico de módulo 3.

Considerando uma única célula da matriz quadrada peculiar, de ordem 4 que aqui se enfoca, haveria 16 possíveis formas diferentes de preenchê-la com os elementos válidos, os algarismos de 1 a 16. Uma vez fixado nesta célula o algarismo, para cada uma das 16 escolhas disponíveis, restariam ainda 15 possibilidades diferentes para preencher a próxima célula considerada. Consequentemente, para a terceira restariam 14 possibilidades e assim sucessivamente. Logo o número total de preenchimentos possíveis desta matriz quadrada seria definido por:

$$A_{16} = 16! = 20.922.789.888.000$$

Cada um destes quase 21 trilhões de diferentes arranjos de preenchimento tem, em princípio, alguma probabilidade de obedecer à regra de gerar somas constantes nas 10 filas: suas 4 linhas, 4 colunas e 2 diagonais. Estas trilhões de possibilidades formam o que se denomina “espaço de pesquisa de soluções” do AG. Como se nota, este espaço se constitui em um conjunto de soluções possíveis de grandeza bastante razoável, embora seu número seja perfeitamente conhecido, o que reforçou a motivação de escolha deste problema.

5.2.2 Algoritmo proposto

DEFINIÇÕES

No algoritmo proposto foram utilizados os conceitos dados a seguir, que apenas formalizam as noções anteriormente referidas.

Seja o conjunto:

$$Q = \|a_{ij}\|, i = 1, \dots, 4 \quad j = 1, \dots, 4$$

onde:

$$1 \leq a_{ij} \leq 16, \text{ sem repetição e } a_{ij} \in I$$

com: $I = \text{conjunto dos inteiros positivos, isto é, dos naturais.}$

Assim Q é o conjunto de matrizes quadradas de ordem 4, cujos elementos são os *naturais* do intervalo $[1,16]$.

Uma matriz particular $Q' \subset Q$, é dita *Quadrado Mágico de Ordem 4* se as 10 somas S_i, S_j, S_{ii}, S_{ij} , abaixo definidas, valem 34.

Nas linhas:

$$S_i = \sum_{j=1}^4 a_{ij} = 34, i = 1, \dots, 4$$

nas colunas:

$$S_j = \sum_{i=1}^4 a_{ij} = 34, j = 1, \dots, 4$$

na diagonal principal:

$$S_{ii} = \sum_{i=1}^4 a_{ii} = 34$$

na diagonal secundária.

$$S_{ij} = \sum a_{ij} = 34, \forall i, j \mid i + j = 5$$

Exemplificando, a matriz

$$Q = \begin{bmatrix} 16 & 9 & 3 & 6 \\ 4 & 5 & 15 & 10 \\ 13 & 12 & 2 & 7 \\ 1 & 8 & 14 & 11 \end{bmatrix}$$

é um Quadrado Mágico, isto é, uma solução do problema, pois as 4 somas das linhas, as 4 das colunas, as da diagonal principal e a da diagonal secundária fornecem todas o valor constante 34.

CODIFICAÇÃO DOS CROMOSSOMOS

A estrutura de cada cromossomo do AG construído para resolver o problema deve retratar a matriz quadrada de ordem 4, formada pelos naturais de 1 a 16. Esta peculiaridade elimina liminarmente a possibilidade de adoção dos códigos de Gray e do binário padrão, tão difundidos na bibliografia de AG ([BÄC 93], [MIT 96], [TAN 95]). Apenas valores inteiros gerados fariam parte da população de soluções possíveis, o que torna impraticável a adoção de tais códigos, de forma direta, pelo menos. Além do mais, a escolha desta codificação implicaria em “over-head” importante na programação computacional e na utilização de UCP, tendo em vista as constantes mudanças de base necessárias. Portanto foi escolhido como codificação cromossômica a própria matriz Q anteriormente definida, com seus elementos representados pelos naturais de 1 a 16, mesmo em nível de linguagem de programação. Para simular o AG foi construído um algoritmo (ver Figura 5.1), implementado apenas com o caráter de validação lógica dos conceitos envolvidos. Não se levou em consideração, portanto, os preceitos de Engenharia de Software no que tange às determinações de ergonomia do produto para o usuário ou quanto à “amigabilidade” das interfaces, que aliás, ficaram reduzidas a simples relatórios impressos e a comandos dados em tempo de execução.

A FUNÇÃO DE APTIDÃO

A função de aptidão (“fitness”) mede o grau de aptidão de um certo indivíduo da população (Ver 4.1.1), com relação ao processo em pauta. Uma boa escolha desta função é importante para o sucesso da aplicação do AG. No Quadrado Mágico, o que se deseja é que as filas consideradas produzam soma 34. Logo, dado um determinado cromossomo Q' , quanto mais próximo a 34 estiver o resultado das suas dez somas S anteriormente definidas, tanto melhor deve ser a qualidade implícita do mesmo para solucionar o problema. No caso particular em que as dez somas têm distância a 34 nula, detectou-se uma solução exata.

A expressão que fornece o valor de aptidão, para melhor retratar a adequação dos indivíduos, deveria tender a zero à medida que a qualidade das soluções testadas também fosse muito baixa ou nula; adicionalmente, deveria ter valor tanto mais alto quanto melhor a aptidão e ainda ser sempre positiva, para qualquer distância.

Conseqüentemente uma primeira idéia seria a de adotar diretamente como função de aptidão, o inverso do somatório das medidas das distâncias (valores absolutos) a 34, de cada uma das dez somas.

Ocorre que, quanto mais próximo à(s) solução (es) estiver um cromossomo em processo de análise pelo algoritmo, tanto maior será a sua aptidão, como definido acima. Mas, no caso especial de uma solução exata, como o Quadrado Mágico exemplificado anteriormente, ter-se-ia uma aptidão nula, já que a distância a 34, de todas as somas parciais, será zero.

A idéia de tomar o inverso das distâncias, torna-se inviável pelo fato de que distâncias pequenas forneceriam valores de aptidão altos, como se deseja, mas as soluções

exatas dariam indeterminação, porque nelas se teria divisão por zero. A solução que contornaria esta dificuldade seria adotar a diferença das distâncias a um valor fixo, conhecido como “off-set” no jargão de CE, superior a todas elas. À medida que as distâncias crescessem, diminuiriam as diferenças ao “off-set”, indicando queda do valor da aptidão.

Outra possibilidade é adotar a função logística, também bastante utilizada na área evolucionária. A função sigmoidal ou logística tem a forma geral:

$$s(x) = \frac{1}{1 + e^{-\alpha x}}$$

possuindo as características de ter seus resultados crescendo de 0 e 1, para valores de distâncias x crescendo de $-\infty$ a $+\infty$, isto é, os resultados da função crescem à medida que os valores positivos das distâncias a 34 se afastam da origem. Assim adotou-se como função de aptidão uma co-irmã da logística, que fornece os complementos em relação a 1 dos resultados desta função:

$$f(x) = 1 - s(x) = 1 - \frac{1}{1 + e^{-\alpha x}} = \frac{e^{-\alpha x}}{1 + e^{-\alpha x}}$$

O parâmetro α foi calibrado para $\alpha = 0,05$, o que fornece, por exemplo, para os valores de distâncias a 34 típicos: 0, 30 e 80:

$$f(0) = 0,5 \quad f(30) = 0,182 \quad f(80) = 0,018$$

OS OPERADORES EVOLUTIVOS

No AG canônico o operador evolutivo por excelência é o de recombinação entre cromossomos escolhidos, mediante processo viesado pela aptidão, mas que ocorre somente se uma taxa pré-definida for observada. Valores típicos desta taxa se situam ao redor de 0,60, isto é, 60% dos cromossomos sorteados sofrem recombinação e os 40% restantes passam à geração seguinte intactos.

O problema do Quadrado Mágico tem um singularidade interessante em relação a este operador pois que o “recombinação canônica”, com inversão entre trechos de cromossomos diferentes, *não é utilizável*. De fato esta metodologia ocasionaria soluções inválidas na quase totalidade das simulações, uma vez que inseririam repetições entre os algarismos de 1 a 16, o que viola a definição. Os únicos casos que produziriam soluções aceitáveis seriam aqueles raros em que os trechos trocados constituíssem valores idênticos, o que só excepcionalmente traria inovações que possibilitassem evolução.

Comparativamente ao processo evolutivo natural, a recombinação “normal”, “padrão” ou “canônica” só daria indivíduos válidos, biologicamente viáveis, se os genes permutados fossem idênticos. Quando estivessem em ordens diferentes nos trechos permutados, haveria geração de novos indivíduos, diferentes dos pais e quando a ordem fosse igual, os indivíduos gerados seriam cópias, idênticas aos pais. Fazer um AG que aceitasse para permutação gênica somente trechos cromossômicos que tivessem os mesmos

genes, em ordem diferente, seria se distanciar por demais do processo biológico, o que evidentemente seria filosofia diametralmente oposta a do objetivo deste trabalho. Portanto a recombinação padrão é inútil em alguns casos, deletério na grande maioria e biologicamente plausível apenas em algumas exceções, o que motivou a rejeição deste operador, adotando-se um sucedâneo.

O segundo operador dos AG canônicos, a Mutação, embora tipicamente funcione como fator marginal (de “background” conforme [BÄC 93]), também é inadequado no caso dos Quadrados Mágicos. De fato, se a mutação de um determinado gene provoca mudança para outro gene válido, isto é, pertencente ao intervalo $[1, 16]$, gera-se como consequência um cromossomo inválido, uma vez que o mesmo gene já existiria no cromossomo que sofreu a mutação: todos os cromossomos iniciais e os gerados devem ser válidos, isto é, com genes no intervalo $[1, 16]$, sem repetição no caso do Quadrado Mágico de módulo 4.

Na outra hipótese, se a mutação inserir um gene fora do aludido intervalo, similarmente o cromossomo resultante será inválido. Conclui-se que a mutação é sempre inútil e mesmo prejudicial, pois que nunca ajuda e sempre atrapalha, produzindo indivíduos inaceitáveis, natimortos.

Um paralelo com a Natureza pode ser feito comparando o caso do Quadrado Mágico com o dos organismos que atingiram um estágio evolutivo tal, que qualquer mudança leva quase sempre à degradação da espécie. Tem-se a impressão que, como nos valores do intervalo $[1, 16]$ do Quadrado Mágico, nestes casos naturais, quase não há genes demais, nem de menos, pois geralmente se referem a seres bem simples da escala evolutiva. Os que compõem os organismos estão próximos aos estritos necessários e a evolução só poderia se dar através de diferentes ordenações do material existente. A criação de novos organismos se verifica pela mudança na organização topológica dos componentes e não pela variação de seu conteúdo informativo. Parece que o exemplo do AG em pauta, com as dificuldades citadas de adoção dos operadores clássicos, indica que quanto mais próximo da solução, isto é, do seu ótimo, encontra-se um organismo, tanto mais dificultoso fica o trabalho de melhorá-lo, de “empurrá-lo” ainda para mais próximo ao pico, e se tem a lembrança de que, geralmente é difícil alterar para melhor um processo se simulação de fatos naturais que os copie fielmente. O dito popular “não se mexe em time que está ganhando” pode ter se originado na observação deste fato, ou pelo menos ele lhe dá sustentação comprobatória.

FORMA DE RECOMBINAÇÃO ADOTADA

Tendo em vista a impraticabilidade da recombinação e da mutação tradicionais, convencionou-se adotar um processo semelhante à “inversão” [MIT 96], em que um trecho de cromossomo é selecionado e simplesmente é permutada sua posição com a de outro trecho correspondente, mas no mesmo cromossomo. No caso do AG implementado para o Quadrado Mágico de módulo 4, nos cromossomos sorteados para comporem a próxima geração sofrendo recombinação, uma linha é randomicamente escolhida e é feita uma inversão de posições entre os elementos de sua primeira metade e os elementos correspondentes da segunda metade da próxima linha. Na eventualidade da linha 4 ser a sorteada, a inversão

é feita entre parte dos elementos dela e parte dos da primeira linha. A simples inversão entre as linhas $i - 1$ e $i + 1$, a partir do sorteio da linha i , como sugerido em [MIT 96], manteria as somas nas linha e nas colunas, modificando apenas as das diagonais. O mesmo aconteceria com a simples inversão da posição de colunas.

Como fundamentação biológica, pode-se dizer que embora este método de recombinação não encontre correspondente natural conhecido na evolução biológica das espécies mais desenvolvidas, o mesmo pode ser comparado, com algum grau de liberdade, ao processo mitótico (3.2.2). A reprodução dos organismos que obedecem a este princípio é feita com uma duplicação inicial de suas células, que na seqüência se bipartem, gerando dois filhos geneticamente idênticos aos pais. A evolução nestes casos está condicionada à alterações de ordem na carga genética e a mutações eventuais. Estas, como se viu, são descartadas no caso do Quadrado Mágico.

UM AG CONSTRUÍDO PARA A SOLUÇÃO DO QUADRADO MÁGICO

Observando os princípios gerais delineados no texto precedente, foi construído em Delphi 3.0, um programa cujos processos principais são mostrados no fluxograma esquematizado na Figura 5.1. Este programa permite o trabalho com populações de, no máximo, 100 indivíduos, gerados aleatoriamente. O número de gerações e a taxa de recombinação também são fornecidas durante a execução. Mediante ligeira mudança, o sistema permite que o conjunto de indivíduos iniciais seja lido em um arquivo previamente montado e gravado em disco, o que fornece uma opção de controle adicional, dos resultados obtidos.

Foi feita inicialmente uma simulação com população de 100 indivíduos, aleatoriamente gerados, taxa de recombinação de 55% e 150 gerações. Constatou-se que a *média das distâncias a 34* das somas das parcelas dos indivíduos da população decai rapidamente, já nas primeiras dez gerações, de valores próximos a 7 para distâncias ao redor de 4, e então permanece oscilando próximo a este valor. O *desvio padrão destas distâncias* tem também um comportamento de queda semelhante nas primeiras gerações, adotando entretanto um lento decrescimento ao longo das gerações seguintes, com oscilações eventuais.

Notou-se que o valor *máximo* destas distâncias tem comportamento diferente. Como nos outros dois parâmetros medidos, também sofre queda brusca no início da simulação mas logo assume valor constante de 15, o que parece indicar a incapacidade do algoritmo de excluir de sua população o piores indivíduos, uma vez atingido determinado grau evolutivo. Obviamente, com certa facilidade se poderia adotar heurísticas que obrigassem a população a extinguir estes seres que mais se afastam do objetivo de convergência da população. Entretanto, frise-se, seriam heurísticas computacionais apenas e dificilmente processos biologicamente inspirados.

O programa também indica, em cada geração, a distância mínima a que os melhores indivíduos chegaram do alvo 34. Com o número relativamente alto de 100 cromossomos, esta distância mínima ficou em zero em todas as gerações, o que seria de esperar.

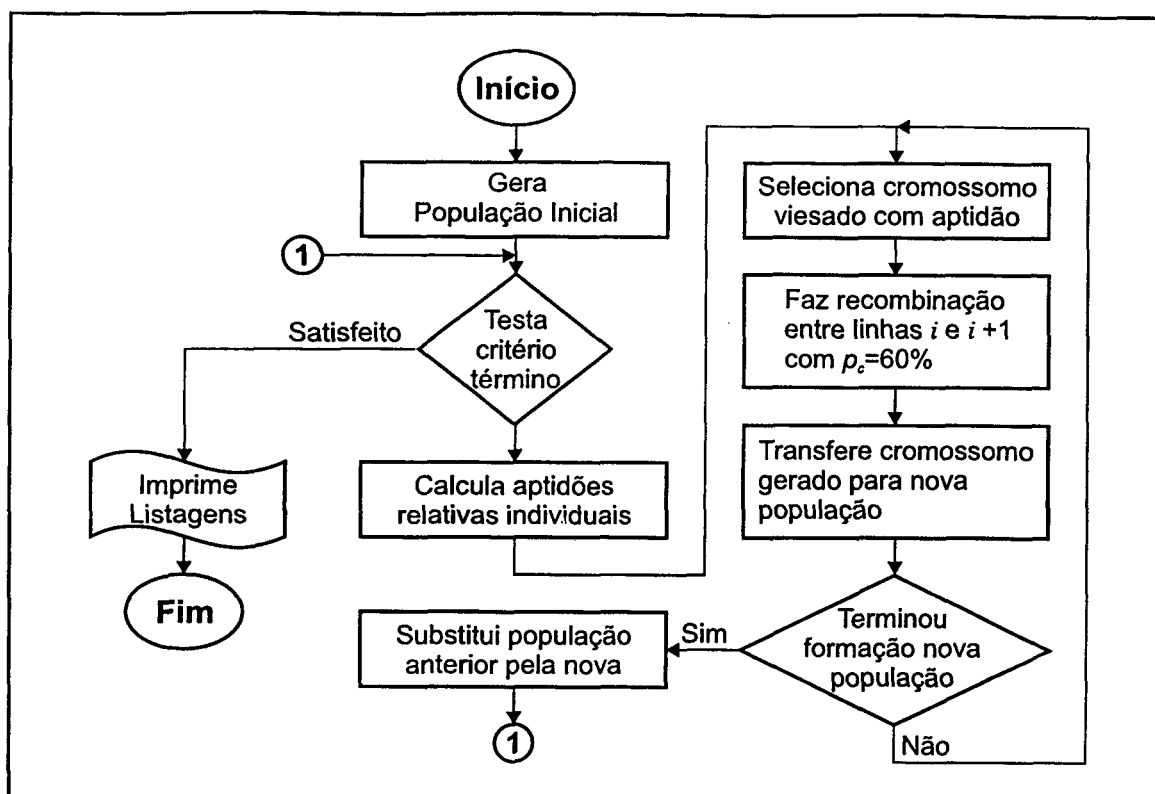


Figura 5.1: Fluxograma de um AG para solução do Quadrado Mágico.

A repetição do processo com número de gerações baixo, isto é, 20, redundou em resultados que mostraram um comportamento quase idêntico ao das primeiras 20 gerações do exemplo de 150 gerações. Isto parece indicar uma estabilização bastante acentuada do modelo ao redor deste número de gerações.

A adoção de taxas de recombinação muito diferentes do valor 55%, sugerida na bibliografia clássica de AG, forneceu os resultados da Tabela 5.1. Observou-se que eles não diferem significativamente dos obtidos com a taxa de 55%, o que aponta para uma certa independência do AG proposto, com relação ao valor desta taxa.

Conclui-se que os operadores padrões do AG quando utilizados na “forma tradicional” não resolvem o problema do Quadrado Mágico. Entretanto técnicas que alteram a “forma tradicional” destas ferramentas poderiam ser utilizadas, talvez com bom resultado. No caso da mutação, uma possibilidade seria a de sortear um elemento da matriz e permutá-lo com outro, de outra posição. Por sua vez cita-se na literatura diversas formas de recombinação, como a *Parcialmente Mapeada* (PMX - *Partially Mapped Crossover*) [GOL 85], a *de Ordem* (OX - *Order Crossover*), a *de Ciclo* (CX - *Cycle Crossover*) que poderiam ser testadas [BOO 97].

Tabela 5.1: Valores fornecidos com taxa de recombinação de 20% e 85%.

<i>Geração</i>	<i>Dist. média</i>		<i>Dist. Máxima</i>		<i>Desv. Padrão</i>	
	20%	85%	20%	85%	20%	85%
1	6,54	6,98	24	24	4,63	5,08
10	3,88	4,70	16	16	3,24	3,59
20	3,50	4,48	13	16	2,87	3,60
30	3,39	4,63	13	16	2,89	3,73
40	3,34	4,75	13	16	2,84	3,67
80	3,43	4,53	13	14	2,88	3,57
120	3,36	4,54	13	14	2,92	3,45
160	3,36	4,73	13	14	2,89	3,61
200	3,26	4,25	13	14	2,87	3,38

5.3 APLICAÇÃO DE AG: EVOLUÇÃO DE RNA

5.3.1 Os AG e as RNA

Os AG e as Redes Neurais Artificiais - RNA - podem ser associadas de diversos modos, classificáveis em três grandes grupos:

- AG para evoluir pesos das conexões sinápticas de RNA de arquitetura previamente fixada;
- AG para encontrar regras de aprendizagem de RNA;
- AG para evoluir arquiteturas de RNA.

1. EVOLUÇÃO DE PESOS DE RNA COM AG

Mitchell [MIT 96] descreve de forma genérica um trabalho em que D. Montana e L. Davis [MON 89] constróem um AG para evoluir 126 pesos - incluindo os de "threshold" - de uma rede direta ("feedforward") totalmente conectada. Sua arquitetura se compunha de 4 neurônios na camada de entrada, 2 camadas intermediárias com 7 e 10 neurônios e apenas um neurônio na camada de saída (já que o problema consistia em classificar dados em apenas duas categorias). Operadores de recombinação e de mutação especiais foram definidos e os resultados mostraram que o AG sugerido naquela pesquisa ultrapassava de forma significativa os conseguidos com o treinamento em retropropagação ("back-propagation"), obtendo-se vetores de pesos das conexões sinápticas melhores e mais rapidamente. Entretanto estes bons resultados da metodologia não se repetem em outros problemas e alguns pesquisadores [WHI 92], sugerem que o AG poderá ser mais útil nos casos onde os métodos de treinamento em retropropagação e/ou assemelhados não se aplicam, como no aprendizado não-supervisionado.

O fato da aplicação do AG ser mais geral, no sentido de ser menos restrito a condições de contorno, pode torná-lo boa alternativa em algumas ocasiões.

Na realidade, o método de treinamento com retropropagação só pode ser utilizado nos casos em que a função de ativação é contínua e derivável. Um exemplo em que é detectada esta problemática de aplicação pode ser visto em [BRA 99]. Em contrapartida, no AG esta condição não é necessária. Infelizmente se tem o fato que no AG a velocidade de convergência é geralmente menor que utilizando o treinamento em retropropagação (em casos em que as duas metodologias sejam aplicáveis). Este fenômeno se deve, provavelmente, a que o ferramental matemático embutido no sistema de retropropagação ajuda a buscar os pontos de mínimo na superfície de erros com mais efetividade que os operadores genéticos disponíveis em AG.

Resultados interessantes foram obtidos com um sistema que utiliza inicialmente AG e, após certo número de gerações, chaveia para RNA treinada com retropropagação. O chaveamento pode se dar também quando a aptidão passa a variar muito lentamente [STE 95].

2. EVOLUÇÃO DE REGRAS DE APRENDIZADO COM AG

O trabalho de Chalmers ([TOU 90, MIT 96]) exemplifica o uso da evolução de regras de aprendizado de RNA utilizando AG. Aquele autor parte da hipótese de que estas regras poderiam ser funções lineares dos parâmetros:

- Vetor de entrada x_i ;
- Vetor de saída obtido o_k ;
- Vetor de saída esperado (correto) y_k ;
- Matriz de pesos w_{ik} , entre os neurônios de entrada i e os de saída k (supondo redes de apenas duas camadas).

Assim as variações nos pesos Δw_{ij} deveriam ser funções lineares envolvendo:

$$\Delta w_{ij} = f(x_i, o_k, y_k, w_{ij})$$

De fato, a bem conhecida “*regra delta*” ou *regra de Widrow-Hoff* [WID 60], ou dos mínimos quadrados ([WID 60, FRE 91, RUM 86b]),

$$\Delta w_{ij} = \eta(y_k o_k - x_i o_k)$$

das mais eficientes no treinamento de redes diretas, é um caso particular da forma sugerida por Chalmers, onde o coeficiente η representa a taxa de aprendizado ou de treinamento [FRE 91]. Usando 30 problemas constituídos de funções de mapeamento linearmente separáveis, resolvidos com redes diretas de duas camadas, os AG sugeridos por Chalmers evoluíram regras de aprendizado eficientes. Todavia conclui que é improvável que os métodos evolucionários cheguem a regras de aprendizado melhores que a de retropropagação, podendo entretanto ser úteis para obter regras em paradigmas não supervisionados, ou para arquiteturas de redes recorrentes.

3. EVOLUÇÃO DE ARQUITETURAS DE RNA USANDO AG

Nesta associação das pesquisas de AG com RNA visa-se geralmente encontrar o número e disposição de camadas de neurônios, o número destes neurônios e as suas interconexões.

A evolução de arquiteturas de redes tem também sido objeto de várias pesquisas que podem ser agrupadas em dois grandes campos: a evolução direta e a evolução indireta ou gramatical [KIT 90].

A motivação principal das investigações nesta direção se prendem ao fato que a configuração arquitetônica de uma rede, tem sido decidida a priori, geralmente através da experiência do programador e mesmo com ajuda de heurísticas que culminam no processo de tentativa e erro [BRA 97]. Como paradigma deste processo, cita-se a regra de Eberhart: “O número de neurônios da camada escondida ³ é igual à raiz quadrada da quantidade de neurônios da camada de entrada mais a quantidade da camada de saída” [EBE 90].

Além deste fato, a importância da existência de um processo automatizado se evidencia com a constatação de que a escolha da estrutura arquitetônica pode levar ao sucesso da aplicação ou ao seu fracasso, em dependência de sua adequação ou não ao problema.

O AG foi um dos enfoques mais pesquisados como possível ferramenta para abordar este problema, tanto na forma *direta*, como na *indireta*.

No primeiro caso o AG trabalha com uma população de cromossomos, representados, por exemplo, em matrizes binárias A onde os elementos a_{ij} representam a presença (se $a_{ij} = 1$) ou ausência (se $a_{ij} = 0$) de conexão entre os neurônios i e j . Adicionalmente, a própria existência do neurônio i na rede poderia ser simulada, com o elemento da diagonal principal a_{ii} igualado a um e a zero em caso contrário.

Supõe-se que estes cromossomos detenham, em sua codificação, características que possam evoluir estruturas arquitetônicas eficientes. Em [MIL 89] há relatos de pesquisas feitas na evolução direta de topologia de redes codificadas em cromossomos, cujas aptidões eram avaliadas mediante os resultados obtidos com sua exposição ao aprendizado de problemas, usando retropropagação como forma de treinamento. Mitchell [MIT 96] aponta a necessidade de mais trabalho que comprove a utilidade da metodologia para casos em que as soluções exijam redes mais sofisticadas que os exemplos relativamente simples testados, sobretudo porque a dificuldade de implementação tende a crescer rapidamente, se aumenta o tamanho das redes.

Tendo em vista estes problemas, diversos pesquisadores, como Kitano [KIT 90], Gruau [GRU 92] e Belew [BEL 93] propõem a alternativa da codificação indireta, em que um AG trabalha com cromossomos constituídos de regras gramaticais a que as estruturas topológicas das redes deverão obedecer. Nas palavras de Mitchell [MIT 96]: “O AG evolui as gramáticas, mas a aptidão é testada somente após dado o passo do desenvolvimento, isto é, após construída a rede obtida pela evolução da gramática. Assim a

³As referências a esta camada nas tabelas deste Capítulo estão feitas com *Cam. H*.

Tabela 5.2: Diagnósticos médicos possíveis para os dados obtidos.

<i>Código</i>	<i>Diagnóstico</i>
1	Espondilite anquilosante
2	Artrite gotosa
3	Artrite reumática
4	Nada

gramática é o genótipo e a rede o fenótipo originado”. Conclui a mesma autora que, embora a alternativa de uso de uma gramática como interface entre os AG e a arquitetura das redes seja intrigante, a simplicidade dos testes realizados para fundamentar as hipóteses levantadas lançam dúvidas sobre a funcionalidade do método em casos de redes mais complexas.

5.3.2 Evolução da arquitetura de uma RNA usando AG

Como referido em [BRA 97], mesmo que se tenha definido o tipo de rede, a quantidade de neurônios e suas inter-conexões, o número de camadas intermediárias e de neurônios de cada uma delas é geralmente escolhido conforme regras empíricas ou pela sensibilidade (“feeling”) do projetista.

Nesta parte do trabalho se mostra o caso da evolução de redes com número variável de neurônios em uma única camada escondida, na busca de um ponto que se espera próximo do ótimo, resultando em redes com erro de saída menor, ou treinadas mais rapidamente, isto é, mais eficientes.

Para testar a possibilidade de obtenção de sistemas que empreguem o AG com mais eficiência, introduzindo técnicas mais biologicamente inspiradas, adotou-se o problema da evolução de RNA, onde o número de neurônios da camada intermediária deve ser evoluído, objetivando redes melhores. Em suma, trata-se de examinar a influência do número de neurônios na camada intermediária na velocidade de aprendizado de um determinado problema, usando para tal processos mais naturalmente inspirados. Foi adotado para teste o caso prático em que a finalidade destas redes é aprender a encontrar as quatro possibilidades de diagnóstico da Tabela 5.2.

Tem-se um banco de 50 casos médicos conhecidos, de pacientes reumáticos, obtidos a partir de dados reais ⁴. Cada caso é constituído de 19 sintomas codificados, além do respectivo diagnóstico dado ao paciente.

Apesar de se ter tido o cuidado de adotar dados colhidos da realidade e o mais confiáveis possíveis, deve-se enfatizar que qualquer imprecisão dos mesmos não invalida a metodologia. De fato, o objetivo não consiste em construir uma ferramenta prática,

⁴Os dados referidos foram compilados, e gentilmente cedidos, pela Dra. Lycia Epprecht, no Hospital de Mont-Godine, Universidade Católica de Louvain, Bélgica.

operacional, para ser implantada em um sistema de saúde real, mas sim verificar se uma metodologia proposta nestes termos pode ser viabilizada, adotando-se características de maior plausibilidade biológica no sistema evolutivo utilizado.

A determinação do número ótimo de neurônios na camada intermediária poderia ter sido feita com o emprego de software disponíveis, como o MATLAB [LAP 00] ou o Qwiknet [JEN 00], mediante testes iterativos. Entretanto, a opção de desenvolver um programa específico, que treine as redes de uma população, foi adotada devido à possibilidade de se acoplar este mesmo programa a um paradigma evolutivo, no caso o AG. Neste paradigma se testou então o efeito de “herança de conhecimento”, simulando o fenômeno observado na Natureza, onde nas espécies mais evoluídas, os indivíduos adquirem conhecimento através do ensinamento dado por gerações precedentes.

A Tabela 5.3 traz os primeiros 40 dos 50 dados clínicos de reumatologia que serviram de teste, já com a parametrização dos seus elementos no intervalo $[0,1]$, exceto a última coluna, que fornece o diagnóstico, conforme a Tabela 5.2. Nas Tabelas 7.1 e 7.4 está disponível a coleta de dados original e lá também se disponibiliza uma descrição sucinta, em termos leigos, da nomenclatura médica envolvida.

Na Figura 5.2 se delinea os grandes blocos que constituem o sistema desenvolvido para o objetivo citado. Uma das telas de interface para entrada de parâmetros foi capturada e é apresentada na Figura 5.3. Os aspectos principais do algoritmo são, a seguir, desenvolvidos.

5.3.2.1 Estrutura de um algoritmo para evoluir a topologia de RNA

PRINCIPAIS PASSOS EXECUTADOS PELO ALGORITMO CONSTRUÍDO

1. POPULAÇÃO INICIAL

Nos primeiros testes foi gerada inicialmente uma população de 15 redes diretas, de 3 camadas completamente conectadas, com número de neurônios na camada escondida variando de 5 a 75, com intervalos de 5. A camada de entrada e a de saída foram mantidas constantes, com 19 e 4 neurônios respectivamente, correspondendo aos 19 sintomas e aos 4 diagnósticos possíveis das Tabelas 5.2, e 5.3, de dados clínicos. Os valores dos elementos das matrizes de pesos sinápticos entre a camada de entrada e a intermediária e desta à de saída, foram gerados aleatoriamente no intervalo $[0,1]$. Estes testes iniciais mostraram que o número de neurônios da camada intermediária está, neste exemplo, diretamente relacionado com o número de épocas necessárias para o treinamento. Os resultados estão comentados com mais detalhe no item 5.3.3.1.

2. TREINAMENTO

Trinta padrões vetoriais de treinamento, isto é, os dados correspondentes aos primeiros 30 pacientes da Tabela 5.3 são submetidos a cada uma das redes da população, durante um número de épocas variável, à escolha do experimentador. Para o treinamento foi usada a retropropagação.

Tabela 5.3: Dados parametrizados com 40 casos médicos de pacientes reumáticos .

Sintomas (Colunas 2-20) e Disgnóstico (coluna 21) (Ver Tabelas 7.1 a 7.5)																				
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21
1	1	0.30	1	1	1	1	1	0.0	0.4	0.7	0	0	0	0	0	0	0	0	0	1
2	0	0.23	0	1	0	0	0	0.0	0.4	0.0	1	0	0	0	0	1	0	0	0	2
3	1	0.30	0	0	0	1	0	0.6	0.4	0.0	1	1	1	1	1	1	0	0	0	2
4	1	0.70	0	0	0	1	0	0.0	0.4	0.0	0	0	0	1	0	1	0	0	0	2
5	0	0.63	0	0	0	0	0	0.6	0.7	0.7	0	0	0	0	0	1	0	0	0	3
6	1	0.59	0	0	0	1	0	1.0	1.0	1.0	1	0	0	1	1	1	0	0	0	2
7	0	0.61	0	0	0	1	0	0.6	1.0	0.0	1	0	0	0	1	1	0	0	0	3
8	1	0.21	1	0	1	0	1	0.6	0.7	1.0	0	0	0	0	0	0	0	1	0	1
9	0	0.56	1	1	0	1	1	0.8	1.0	1.0	1	1	0	0	1	1	0	0	0	3
10	0	0.72	0	0	0	1	0	1.0	0.0	0.7	1	1	0	0	1	1	1	0	0	3
11	1	0.24	1	1	1	1	1	0.6	0.7	0.0	0	0	0	0	0	0	0	1	0	1
12	0	0.77	0	0	0	1	0	0.3	0.4	0.0	1	0	0	0	1	1	0	0	0	3
13	1	0.57	0	0	0	1	0	1.0	0.0	0.0	1	0	0	0	1	1	0	0	0	2
14	0	0.74	0	0	0	1	0	0.8	0.0	0.4	1	1	0	0	1	1	0	0	0	3
15	0	0.35	0	0	0	0	0	0.0	0.0	0.0	0	0	0	0	0	0	0	0	0	4
16	0	0.21	1	0	0	0	0	0.3	1.0	0.0	0	0	0	0	0	0	0	0	0	1
17	1	0.46	0	0	0	1	0	0.6	0.4	0.0	1	0	0	1	0	1	0	0	0	2
18	0	0.70	0	0	0	0	0	0.3	0.7	0.0	1	1	0	0	1	1	0	0	0	3
19	1	0.57	1	1	1	1	0	0.6	1.0	0.7	1	0	0	0	0	1	0	1	1	1
20	1	0.41	1	0	0	0	0	0.6	0.0	0.0	1	0	0	0	1	1	0	1	0	1
21	0	0.72	0	0	0	1	0	0.8	0.0	0.7	1	1	0	0	1	1	0	0	1	3
22	1	0.59	0	0	0	0	0	0.3	0.7	0.0	1	0	0	1	1	1	0	0	0	2
23	0	0.18	1	0	0	0	0	0.0	0.4	0.7	0	0	0	0	0	1	0	1	0	1
24	1	0.28	1	1	0	0	1	0.0	0.4	0.4	0	1	0	0	0	0	0	1	0	1
25	1	0.22	1	0	1	0	0	0.0	0.7	0.0	0	0	0	0	0	0	0	1	0	1
26	1	0.27	0	0	0	0	0	0.8	0.0	0.0	0	0	1	0	0	1	1	0	0	3
27	1	0.40	1	1	0	0	0	0.3	0.7	1.0	0	0	0	0	0	0	0	1	0	1
28	0	0.63	1	1	0	0	0	0.0	0.0	0.0	0	1	0	0	0	1	0	0	0	3
29	1	0.69	0	0	0	1	0	0.6	0.4	0.7	1	0	0	0	0	1	0	0	0	2
30	1	0.65	0	0	0	1	0	0.8	0.7	0.7	1	0	1	1	1	1	0	0	0	2
31	1	0.32	1	1	1	0	0	0.0	0.7	0.0	0	0	0	0	0	0	0	1	0	1
32	1	0.50	0	0	0	0	0	0.8	0.7	0.0	1	1	1	1	0	1	0	0	0	2
33	1	0.38	1	0	0	0	1	0.6	0.7	0.0	0	1	0	0	0	0	0	1	0	1
34	0	0.54	0	0	0	1	0	0.3	0.7	0.0	1	1	0	0	1	1	0	0	0	3
35	1	0.55	0	0	0	1	0	0.3	0.4	0.0	1	1	0	0	1	1	0	0	0	3
36	1	0.39	1	1	0	0	1	0.0	0.7	1.0	0	1	0	0	0	1	0	1	0	1
37	1	0.38	0	0	0	0	0	0.8	0.4	0.0	1	0	1	1	1	1	0	0	0	2
38	1	0.57	0	0	0	1	0	0.6	0.0	0.0	0	0	1	1	0	0	0	0	0	2
39	0	0.64	0	0	0	1	0	0.6	0.7	0.0	1	0	0	0	1	1	0	0	0	3
40	1	0.70	0	0	0	0	0	0.8	0.7	0.0	1	0	0	0	1	1	0	0	0	3

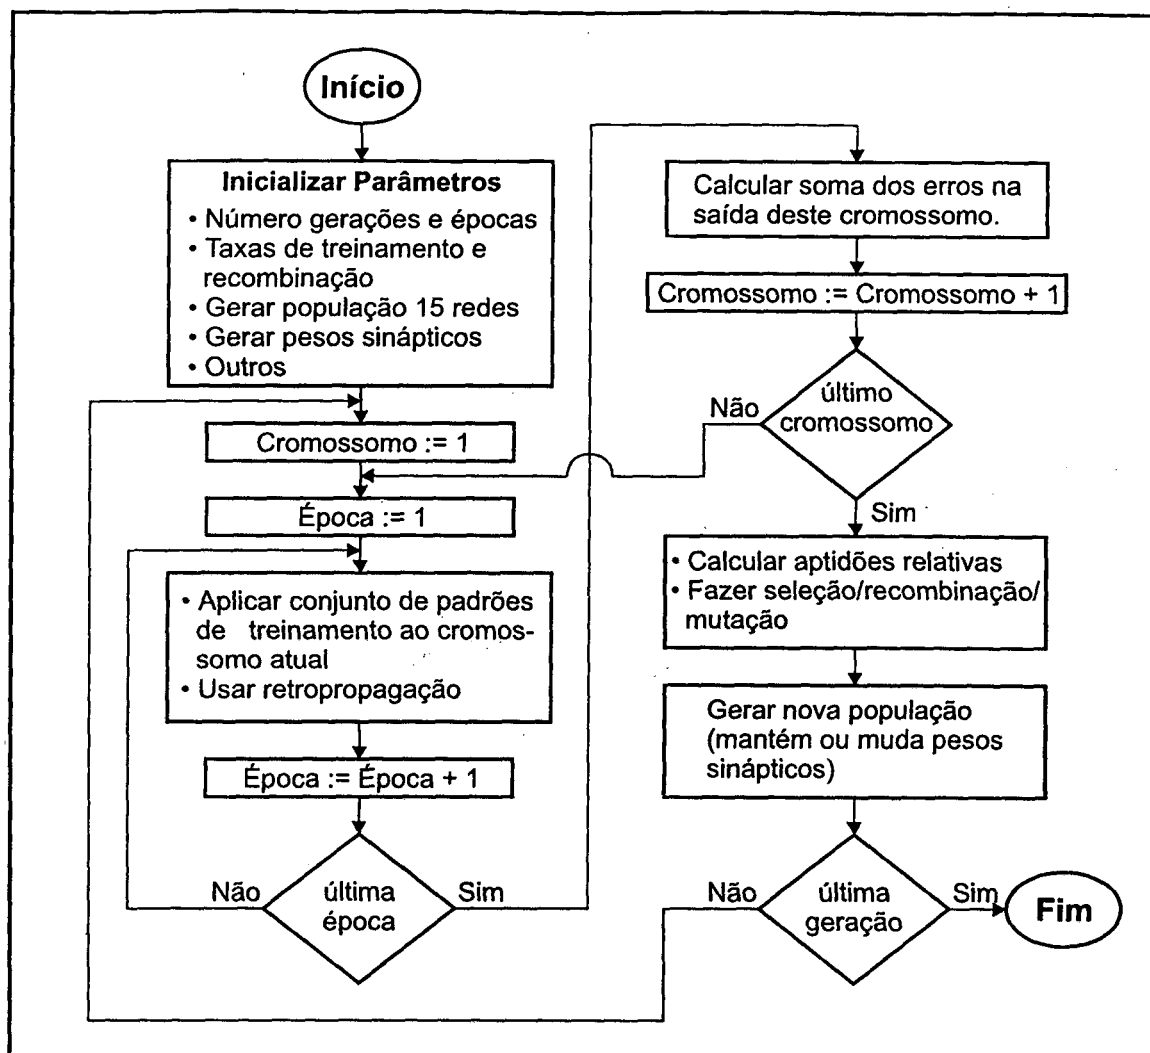


Figura 5.2: Fluxograma genérico para emprego de AG na evolução da arquitetura de RNA.

O treinamento pode ser feito com diferentes critérios de parada, sendo os mais habituais o número de épocas de treinamento, um nível de erro pré-definido, o tempo de CPU usado para o treinamento, o instante em que o processo passa a evoluir a uma taxa previamente especificada, etc. Neste caso, o número de épocas foi o critério de parada adotado.

3. OBTENÇÃO DO ERRO E FUNÇÃO DE APTIDÃO

Após a última época de treinamento é medido o erro nas 4 componentes do vetor de saída. Uma extensão do conceito de distância de Hamming [FRE 91] foi utilizado para definir este erro, isto é, tomou-se os módulos das diferenças entre os valores desejados (o diagnóstico correto fornecido pela Tabela 5.2) e os obtidos com o treinamento.

No conceito de distância está implícito que se consideram os módulos das diferenças entre os valores obtidos e os desejados, para que o valor final não seja mascarado com eventuais erros negativos contrabalançando positivos. Quanto maior o somatório das

Evolução da Arquitetura de RN com AG

Aplicação: Dados Reumatológicos

Parâmetros do Algoritmo Genético

Número de Gerações

Taxa de Recombinação

Número de Indivíduos da População

Parâmetros das Redes Neurais

Número de Épocas

Taxa de Aprendizado

Número Inicial de Neurônios da Camada Intermediária

☐ Ler do Arquivo

☒ Valor Default

Tipo de Evolução

☒ Sem Herança ☐ Com Herança

Figura 5.3: Interface de sistema com emprego de AG na evolução da arquitetura de RNA.

distâncias, maior a inadequação do cromossomo considerado. Então o inverso do erro é uma boa sugestão para medir a aptidão do indivíduo. A hipótese de erro nulo, provocando um pondo de indeterminação na função de aptidão, não é impossível. Um contorno para esta hipótese é a adoção da função sigmóide ou logística [FRE 91], como feito no problema do quadrado mágico 5.2.2. Entretanto, considerando que dificilmente ocorrerá um estágio de treinamento que anule completamente o erro residual (contrariamente ao que ocorria no algoritmo do quadrado mágico), seu inverso foi adotado como função de aptidão, nesta implementação.

Obtém-se, com o procedimento exposto, um erro para cada padrão e seu somatório fornece o erro total da rede após o número de épocas pré-definido. Tem-se assim o erro oriundo de cada um dos indivíduos da população de redes. Calculou-se a média e o desvio padrão destes erros ao longo de diversas gerações. As Tabelas 5.4 e 5.5, por exemplo, ilustram alguns valores obtidos.

Uma observação interessante, e talvez potencialmente rica como tema de pesquisas, advém dos conhecimentos de álgebra linear. Se a camada intermediária tem o número de neurônios igual ao número de vetores de treinamento, então estes neurônios poderiam ser pensados como formando uma base (conjunto de vetores linearmente independentes de um determinado espaço vetorial - [HAD 73]), que gerasse sem erro (ou $erro = 0$), o conjunto de vetores de treinamento ([BAR 01, CEL 91]). É possível ainda ocorrer o

caso em que alguns parâmetros de treinamento sejam linearmente dependentes e então o número de neurônios da camada intermediária poderia mesmo ser inferior ao do número de parâmetros de treinamento.

O problema se assemelha ao de encontrar polinômios que passem por um conjunto de pontos dados. Sabe-se que apenas um polinômio, o de grau n , passa *exatamente* por $n + 1$ pontos. O erro é nulo quando se opta por representar um conjunto de pontos por um polinômio de grau maior ou igual à cardinalidade deste conjunto. Mas se for escolhido $\text{grau} \geq n + 1$, ter-se-á um número indeterminado de polinômios solução.

Por exemplo, há uma infinidade de parábolas que passam por 2 pontos dados, e apenas uma reta. Se, dados 3 pontos opta-se por uma reta para representá-los, ela passará por 2 apenas e, se eles forem oriundos da medição de um fenômeno aproximadamente linear, pode-se esperar que o terceiro estará relativamente próximo à reta escolhida. Em outras palavras, a reta poderá ser usada para extrapolar a posição deste terceiro ponto. Em [CAR 95] se encontra explicação interessante sobre este tema.

O relacionamento do erro, nesta aplicação, com o número de neurônios da camada intermediária será aprofundado no item 5.3.3.1.

4. FORMAÇÃO DAS NOVAS POPULAÇÕES - OPERADORES EVOLUCIONÁRIOS

O somatório das componentes do vetor de saída de cada padrão de treinamento, após a última época, fornece a aptidão de cada indivíduo da população de RNA. Faz-se a seleção, sendo adotado o método de escolha de indivíduos proporcionalmente à sua aptidão relativa, implementada através do processo cognominado “roleta” [BAR 01]. Sorteado um par de indivíduos da população atual, verifica-se se sofrerão recombinação, o que ocorrerá numa proporção dada pelo usuário, sendo 60% dos casos um valor típico. Na ocorrência de recombinação, gera-se um novo indivíduo, cuja camada intermediária terá um número de neurônios correspondendo à “média aritmética inteira” (adota-se somente a parte inteira do valor da média calculada, caso não seja exata, isto é, trunca-se a parte decimal) entre os números correspondentes dos dois indivíduos geradores. Na eventualidade de não ocorrer recombinação, o número de neurônios do primeiro ou do segundo indivíduo gerador, cada qual com a mesma probabilidade, passa incólume para a nova população.

A ocorrência de mutação é simulada mediante a geração de um indivíduo com número de neurônios da camada intermediária entre 1 e o número máximo simulado (75 na população trabalhada inicialmente), sempre que houver ocorrência deste evento. Este é deflagrado com uma frequência adotada à conveniência do usuário. Geralmente toma-se percentuais bem abaixo de 0,5%.

O processo descrito é repetido até que se forme nova geração populacional de RNA e então elas são apresentadas novamente aos padrões de treinamento, os dados clínicos reumatológicos.

O número de gerações também é um parâmetro definível pelo usuário. No algoritmo testado, onde as populações são constituídas por um baixo número de indivíduos,

verificou-se que 5 ou 6 gerações são suficientes para a obtenção de resultados satisfatórios.

5. OUTROS PARÂMETROS

Saliente-se novamente que não se teve a preocupação de construir um programa de eficiência ótima para solução do problema dos diagnósticos de casos reumáticos e consequentemente não foram implementadas ferramentas conhecidas, que geralmente melhoram a performance das redes. Cita-se como exemplos:

- Inserção de um *neurônio de "polarização"*, na camada intermediária, com saída constante e unitária. Sendo opcional [FRE 91], este recurso não foi utilizado;
- *Taxa de aprendizado*. Geralmente, quando estas taxas assumem valores mais baixos há necessidade de um maior número de iterações para que a rede treine. Atente-se entretanto para o fato de que maiores taxas implicam muitas vezes em oscilação da rede em torno da solução, dificultando a estabilização [FRE 91]. Adotou-se a taxa $\eta = 0,10$;
- *Momento*: Para ajudar a rede a manter as mudanças dos pesos em uma mesma direção, a do erro mínimo, sugere-se adicionar à variação atual dos pesos, uma fração da variação imposta na iteração precedente. Também este recurso não foi implementado, uma vez que os testes mostraram uma convergência suficientemente rápida com poucas iterações.

GENÓTIPO E FENÓTIPO

O organismo final já estruturado, isto é, o fenótipo, desenvolvido com a indicação dada pelos operadores evolucionários, é constituído pelas matrizes de pesos das RNA, para as quais o AG fornece valores de números de neurônios da camada intermediária. Como os números possíveis, no caso das redes escolhidas, são inteiros extraídos de um intervalo relativamente pequeno, isto é, de 1 a 75 (na população "teste" inicial), optou-se por trabalhar diretamente com eles, em lugar de sua representação prévia em populações constituídas de cromossomos binários. Poder-se-ia realizar as operações evolucionárias de seleção, recombinação e mutação para gerar as novas populações, em uma população genotípica de cromossomos binários. Entretanto, conhecendo-se os resultados possíveis, e sendo estes em número não tão grande, optou-se por contornar este passo e emular diretamente o fenótipo desejado.

Um cromossomo binário para gerar o número de neurônios da camada intermediária poderia ser simulado com um vetor de 7 bits, o que geraria números entre 0 (zero) e $2^7 = 128$. Um trabalho de mapeamento para o intervalo [1,75] deveria portanto ser feito.

A causa principal desta escolha se deu levando em consideração o acréscimo de trabalho de programação e tempo posterior de execução, se fossem inicialmente gerados cromossomos binários, evoluídos e posteriormente convertidos para base decimal, aproveitando-se apenas os valores que estivessem no intervalo [1, 75].

5.3.3 Influência da “herança de conhecimento” na evolução de RNA com AG

Neste trabalho, a utilização de AG para evoluir RNA's pode ser aplicada de duas formas, cada qual refletindo, em maior ou menor grau, o inter-relacionamento dos indivíduos que constituem as populações simuladas e seus antecessores.

O desenvolvimento aqui explanado se baseia na hipótese de que os pesos das conexões sinápticas interneurais das RNA simulam, no seu todo, o conhecimento da rede [LAN 95], daí que os processos de adequação destes pesos a problemas específicos são cognominados “métodos de aprendizado ou de treinamento”. Esta hipótese deriva da famosa *lei de Hebb*: “Quando um axônio da célula A está suficientemente próximo para excitar a célula B e repetida ou persistentemente toma parte no seu disparo, ocorre um processo de crescimento ou de troca metabólica em uma ou em ambas as células, de tal forma que aumenta a eficiência de A, como uma das células que disparam B” [HEB 49].

As interações entre as células neurais dos organismos se dão sobretudo via conexões sinápticas e daí decorre o palpite de que as mudanças provocadas pelo processo de aquisição de conhecimento, devem ter lugar, prioritariamente, nestas conexões. O modelo de neurônio de McCulloch-Pitts [MCC 43] se origina nesta conjectura.

De forma comparável ao baixo poder de computação do transistor nos computadores digitais, nas RNA grande poder computacional é conseguido através da simulação do funcionamento dos neurônios, que constituem sua unidade básica de construção. Com a interveniência de um trabalho massivamente paralelo, a repetição de numerosas operações elementares produz resultado final surpreendente, com um salto do simples ao complexo [MIN 91] que lembra a emergência do pensamento.

No Capítulo 2, foi levantada a suposição, sustentada por diversos pesquisadores, dentre os quais destaca-se H. Gardner [GAR 94], que os indivíduos com maior tempo de convivência com seus pais, têm maior possibilidade de deles absorver os conhecimentos já desenvolvidos e, conseqüentemente, evoluir mais rapidamente.

No exemplo em pauta, sugere-se uma forma de utilizar o AG, juntamente com as RNA, para testar aspectos desta hipótese. Para tal se fazem experimentações a seguir discutidas.

5.3.3.1 Simulação da evolução de RNA “sem herança de conhecimento”

1. O QUE É HERDADO

No primeiro caso se supõe que os indivíduos se sucedem, nas gerações consecutivas, sem transmissão de conhecimento (pesos sinápticos), isto é, cada nova geração de indivíduos, mesmo que haja entre eles elementos advindos da população anterior, isto é, com idêntico número de neurônios na camada intermediária, não usufrui de nenhum conhecimento já sedimentado. Entretanto, a estrutura, a topologia da rede, é herdada pelos que sobreviveram. Os que sofrem recombinação e os advindos de mutação não herdam a topologia original. Na prática, cada nova população parte de um conjunto de

Tabela 5.4: Influência da Camada Intermediária e do número de épocas.

Rede	Cam.H	Épocas de Treinamento			
		50	100	150	1000
1	5	35.30	26.76	12.30	3.32
2	10	37.63	15.51	23.48	3.54
3	15	40.40	17.41	12.54	2.96
4	20	82.88	81.49	43.21	2.07
5	25	89.99	89.99	89.94	89.98
6	30	89.99	89.99	89.99	44.50
7	35	90.00	90.00	89.99	90.00
8	40	90.00	90.00	90.00	90.00
9	45	90.00	90.00	90.00	90.00
10	50	90.00	90.00	90.00	90.00
11	55	90.00	90.00	90.00	90.00
12	60	90.00	90.00	90.00	90.00
13	65	90.00	90.00	90.00	90.00
14	70	90.00	90.00	90.00	90.00
15	75	90.00	90.00	90.00	90.00
Erro médio		79.08	75.45	72.10	63.76
Desvio Padrão		21.47	28.91	31.45	39.68

pesos sinápticos totalmente aleatória e o AG só interfere para indicar, em cada geração, quais os indivíduos com número de neurônios da camada intermediária de maior aptidão e evolui-los, dando-lhes maiores chances de figurar na próxima geração. Esta simulação pretende mostrar a evolução de espécies onde não há passagem de ensinamento entre ascendentes e descendentes.

2. AJUSTES INICIAIS NOS PARÂMETROS DO AG E DO ALGORITMO

O número de neurônios da camada intermediária de cada rede foi, nos primeiros testes, retirado do conjunto

$$H = [5, 10, \dots, 75]$$

adotado de forma totalmente arbitrária. Para validar esta escolha, foram feitos vários testes que indicaram a sensibilidade da metodologia a estes valores. Inicialmente se fez necessário verificar um número de épocas razoável, a que as redes deveriam ser submetidas. Estando tão somente em questão a resposta a este parâmetro, variou-se apenas o número de épocas necessárias para treinar cada uma das redes da população, fixando-se então em apenas *um* o número de gerações. A Tabela 5.4 indica os erros obtidos para cada rede treinada, após 50, 100, 150 e 1000 épocas.

Na tabelas onde se mostra erros de redes, a não ser quando explicitamente citado, ele se

refere ao somatório dos desvios das componentes dos vetores de saída, dos 30 vetores de treinamento. Assim, um erro de 90 unidades indica que não houve treinamento algum. Este valor resulta do fato de serem aplicados a cada época 30 padrões de treinamento (os 30 primeiros da Tabela 5.3), com cada um gerando, na saída da rede, um vetor de 4 componentes. Quando a rede está completamente treinada, 3 destas componentes deverão estar valendo *zero* e a quarta valendo *um*, na saída de cada padrão, indicando o diagnóstico a ele referente.

Por exemplo, se o vetor de saída indicado pela rede for $O = [0, 0, 1, 0]$, ter-se-ia um diagnóstico “3 - *Artrite Reumática*”, conforme Tabela 5.2. Este deveria ser o vetor de saída para os padrões 5, 7, 9, 10, etc. (Tabela 5.3), se a rede estivesse bem treinada. Se a rede indica *erro* = 90, se conclui que nos 30 padrões a ela submetidos naquela época, se teve saída 1 em todas as 4 componentes, ocasionando uma “distância de Hamming” (5.3.2.1) de uma unidade em cada componente, exceto na que indica diagnóstico correto, que terá esta distância nula. Portando se obtém os erros dos 30 padrões, cada um deles com 3 distâncias valendo 1 e totalizando 90.

Os dados tabulados em 5.4 indicam que, apesar de apenas 50 épocas serem suficientes para o algoritmo começar o treinamento da população até a rede 6 (com 30 neurônios escondidos), quando se dobra para 100 épocas de treinamento, este erro ainda permaneceu alto para todas as redes. Somente a partir de 150 épocas conseguiu-se uma redução substancial do erro das 4 primeiras redes.

Para obter uma indicação do número de épocas necessárias para treinar as redes de mais nós na camada intermediária, testou-se 1.000 épocas. O tempo de processamento que ficava ao redor de 2 minutos⁵ quando se tinha 150 épocas, subiu então para aproximadamente 10 minutos. Mesmo assim, apenas as 4 primeiras redes tiveram bom treinamento, com a 5ª e a 6ª apresentando algum treinamento, mas erro alto. As redes com 35 ou mais neurônios escondidos não sofreram qualquer treinamento (*erro* = 90).

Para testar a hipótese do algoritmo construído estar treinando apenas os primeiros indivíduos da população de redes, inverteu-se o processo de treinamento, apresentando-se os padrões primeiramente aos indivíduos com maior número de neurônios intermediários. Adicionalmente, ampliou-se o limite de épocas para 10.000. Os resultados conseguidos para 1.000 e 10.000 estão tabulados em 5.5.

Os valores tabulados indicam mais uma vez que o treinamento ocorreu, com baixo erro, apenas em redes com até 30 neurônios na camada intermediária. Redes com 35 e 40 neurônios foram razoavelmente “calculados” e aqueles com 45 neurônios ou mais não foram sequer tocados pelo treinamento, mesmo após um tempo de processamento de pouco mais de 2,5 horas, necessário para testar as 10.000 épocas.

Das Tabelas 5.4 e 5.5 se conclui que não adianta, neste exemplo, adotar redes com mais que 30 neurônios escondidos, pois as mesmas exigiriam número de épocas exageradamente elevado para serem treinadas, ao custo de tempos de processamento inviáveis.

⁵Os resultados indicados ao longo deste trabalho foram obtidos em ensaios feitos em microcomputador com CPU Intel Pentium MMX, 64 MB de RAM.

Tabela 5.5: Influência da Camada Intermediária e do número de épocas (caso “descendente”).

Rede	Cam.H	Épocas de Treinamento	
		1000	10000
1	75	90.00	90.00
2	70	90.00	90.00
3	65	90.00	90.00
4	60	90.00	90.00
5	55	90.00	90.00
6	50	90.00	90.00
7	45	90.00	90.00
8	40	90.00	49.43
9	35	89.99	20.83
10	30	89.99	0.47
11	25	3.98	0.45
12	20	2.51	0.45
13	15	2.51	0.46
14	10	2.83	0.56
15	5	3.26	0.77
Erro médio		61.01	46,89
Desvio Padrão		42.44	43.58

A partir destes experimentos a metodologia passou a adotar redes com no máximo 30 nós intermediários. As populações foram inicializadas com indivíduos, tendo na camada intermediária da primeira geração, o número destes nós retirados do novo conjunto $H' = [2, 4, 6, \dots, 30]$.

O número de épocas preferencialmente escolhido foi de 150 que, como mostrado na Tabela 5.4, fornece valores de erro suficientes para aplicar o operador de seleção no AG.

3. ALGUNS RESULTADOS TÍPICOS OBTIDOS

Definidos os limites razoáveis de variação do número de neurônios e do número de épocas que propiciassem valores de erros adequados à aplicação do operador de seleção no AG, passou-se à simulação propriamente dita.

Com as redes assumindo na camada escondida número de neurônios definido pelo conjunto H' , atribuiu-se valores aleatórios no intervalo $[0,1]$ aos pesos das conexões sinápticas entre os neurônios de entrada e os da camada intermediária. Fez-se o mesmo com os desta aos da camada de saída.

Em seguida treinou-se cada rede por 150 épocas, apresentando-se em cada época os 30 primeiros padrões da Tabela 5.3, utilizando-se o processo da retropropagação.

Após a 150^a época de treinamento mediu-se os erros de cada rede e aplicou-se o AG, selecionando-se as melhores, em função do erro de saída encontrado, recombina-se e mutando-se o número de neurônios das camadas intermediárias destas redes selecionadas, conforme descrito no item 5.2.2, para o problema dos Quadrados Mágicos. A aplicação das ferramentas do AG resultaram na definição de uma nova população de redes, agora com números de neurônios mais adequados, espera-se.

À nova população de redes foram novamente atribuídos pesos aleatórios para as conexões sinápticas entre os neurônios das três camadas e o processo de treinamento se repetiu, novamente por 150 épocas. Esta sistemática foi sucessivamente empregada ao longo de 6 gerações consecutivas e a tabela 5.6 traz um resumo da evolução dos valores dos números de neurônios selecionados pelo AG, com respectivos erros de saída, para a 1^a, 2^a, 4^a e 6^a gerações.

A Tabela 5.7 traz os acertos obtidos pelas diferentes 15 redes, nas gerações pares, após a 10^a, 50^a, 100^a e 150^a época de treinamento.

Da observação dos valores mostrados nas Tabelas 5.6 e 5.7 se destaca os seguintes pontos:

1. Em cada geração, o número de acertos depende praticamente apenas do número de neurônios escolhido e do número de épocas considerado. Na 2^a geração, o cromossomo 1, com 26 neurônios escondidos e o 15, com 22 neurônios, tiveram zero acertos. Algo similar ocorreu com o cromossomo 1 da 4^a geração, que teve apenas 9 acertos em 30, após 150 épocas de treinamento e zero acertos nas demais épocas tabuladas. Este baixo índice de eficiência era já indicado pelos erros evidenciados na Tabela 5.6, que aponta

Tabela 5.6: Evolução das RNA ao longo de 6 gerações e 150 épocas, *sem herança*.

Rede	Geração 1		Geração 2		Geração 4		Geração 6	
	Cam.H	Erro	Cam.H	Erro	Cam.H	Erro	Cam.H	Erro
1	2	26.254	26	90.000	19	28.912	13	11.441
2	4	27.075	4	13.420	9	12.240	9	11.032
3	6	10.606	6	18.537	9	11.200	11	13.178
4	8	11.670	12	12.080	14	11.238	9	11.638
5	10	12.055	12	15.217	11	11.830	12	13.364
6	12	10.153	14	10.349	11	13.126	12	13.707
7	14	11.800	12	10.800	10	10.523	12	11.924
8	16	16.297	5	18.777	11	10.320	9	10.923
9	18	56.119	8	14.017	14	12.247	10	10.755
10	20	38.250	10	10.217	4	17.468	4	16.101
11	22	61.312	14	10.838	14	12.319	13	9.677
12	24	73.779	12	11.800	9	11.214	10	12.620
13	26	89.997	12	13.279	10	10.245	14	20.391
14	28	90.000	11	9.639	12	10.870	9	11.852
15	30	90.000	22	89.995	5	15.135	9	11.412
Erro Médio		41,69		23,26		13,26		12,67
Desv.Padr.		32,03		27,24		4,74		2,63

Tabela 5.7: Número de saídas corretas na fase de treinamento das redes, *sem herança*.

Rede	Geração 2				Geração 4				Geração 6			
	Épocas				Épocas				Épocas			
	10	50	100	150	10	50	100	150	10	50	100	150
1	0	0	0	0	0	0	0	9	0	0	19	29
2	0	0	10	26	0	0	17	28	0	0	20	29
3	0	7	10	18	0	0	21	29	0	0	12	24
4	0	0	14	29	0	0	16	29	0	0	20	29
5	0	1	12	25	0	0	18	27	0	0	16	26
6	0	1	22	29	0	3	16	28	0	0	10	27
7	0	3	19	28	1	4	23	28	1	0	9	28
8	0	2	10	17	1	0	22	28	0	4	20	27
9	0	0	10	25	0	3	9	26	0	0	20	29
10	0	2	24	29	0	0	10	20	0	0	10	22
11	0	0	18	27	0	1	11	25	0	0	24	28
12	0	2	21	28	0	3	22	29	0	0	16	28
13	0	0	9	26	0	1	23	28	0	2	1	17
14	1	2	24	29	0	0	21	29	0	2	21	29
15	0	0	0	0	0	1	10	24	0	0	23	29

Tabela 5.8: Percentuais de acerto de cada rede, ‘em tempo de verificação’, *sem herança*.

Rede	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Cam. H	13	9	11	9	12	12	12	9	10	4	13	10	14	9	9
% Acertos	65	65	65	65	65	65	60	65	65	65	50	65	40	65	65

baixo nível de treinamento para as redes com número de neurônios intermediários acima de 18.

Entretanto o AG, em razão de sua forma de funcionamento, não exclui de forma imediata, já nas primeiras gerações, os piores elementos.

2. A evolução do número de acertos se faz de modo crescente, com as gerações e com as épocas tabuladas. Sem rigorismo, pode-se notar que em todas as gerações tabuladas em 5.6, exceto para as apontadas no item anterior, os primeiros acertos das redes começam a aparecer ao redor da 50ª época de treinamento. A partir desta etapa o treinamento melhora de forma monotonicamente crescente até atingir 29 acertos em 30, nas redes mais bem sucedidas.
3. Observou-se que o único padrão não treinado, no caso de 29 acertos, foi o de número 15. Verifica-se que só este padrão 15 tem *diagnóstico 4*, isto é, *Normal*, conforme tabelas 5.2 e 5.3. Este ponto parece estar “descolado” dos demais, no conjunto de características intrínsecas que se supõe existir entre os padrões e se pretende sejam detectadas pelas redes treinadas, razão pela qual possivelmente as redes encontram dificuldade em classificá-lo.
4. O número médio de neurônios intermediários das 15 redes trabalhadas parte de 16, na primeira geração, baixa para 12 na segunda e vai decrescendo, também monotonicamente, tendendo à estabilização em torno de 10 neurônios na 6ª geração.
5. Deve-se observar que, tanto na Tabela 5.5, quanto na 5.4, o erro médio decresce, pois as redes com melhor topologia (com número de nós escondidos de maior aptidão) são treinadas mais intensamente. Inversamente, o desvio padrão cresce, apontando o fato que as redes menos adaptadas são preteridas, em termos de treinamento, para as últimas épocas. Em outras palavras, a metodologia investe mais e primeiramente nas “melhores” redes.

Para testar o nível de acerto relacionado com a capacidade de extrapolação das redes treinadas *sem herança*, os últimos 20 padrões da Tabela 5.3 foram injetados nas redes da última geração obtida com o AG implementado e tabulou-se em 5.8 os percentuais de diagnósticos corretos ⁶ produzidos.

⁶O vetor de saída foi considerado correto se nenhuma de suas componentes se diferencia em mais que 30% do valor de saída esperado.

Tabela 5.9: Amostra da saída da rede, em período de verificação, com 65% de acertos.

Padrão	Neurônios				Padrão	Neurônios			
	1	2	3	4		1	2	3	4
31	0.937	0.055	0.018	0.048	41	0.037	0.177	0.785	0.040
32	0.022	0.864	0.185	0.048	42	0.942	0.039	0.024	0.054
33	0.927	0.032	0.032	0.045	43	0.035	0.043	0.958	0.054
34	0.030	0.087	0.908	0.040	44	0.028	0.451	0.651	0.056
35	0.023	0.608	0.471	0.045	45	0.528	0.196	0.074	0.045
36	0.835	0.053	0.053	0.039	46	0.351	0.058	0.372	0.038
37	0.041	0.887	0.091	0.049	47	0.024	0.473	0.572	0.041
38	0.177	0.858	0.028	0.066	48	0.037	0.044	0.956	0.056
39	0.036	0.151	0.815	0.041	49	0.883	0.043	0.055	0.047
40	0.074	0.617	0.195	0.048	50	0.654	0.187	0.056	0.058

Para fornecer uma idéia dos resultados obtidos na fase de verificação das redes, em 5.9 se esquematiza uma amostra das 4 componentes do vetor de saída de cada padrão, construída com os de número 31 a 50 (a Tabela 5.3 traz os 10 primeiros destes padrões). Esta Tabela mostra as saídas geradas pela rede número 1, com 13 neurônios escondidos, tendo fornecido um nível de acerto de 65%.

Como o objetivo do algoritmo não está em constituir-se numa ferramenta a ser aplicada, pelo menos de imediato e na forma atual, nenhum esforço de melhoria dos níveis de acerto foi executado. Um exemplo típico de tal esforço poderia ser o de se conseguir mais padrões tipo *diagnóstico normal*, tão mal enquadrado pelas redes enquanto treinadas, talvez por ter sido o único disponível entre os 50 da Tabela 5.3.

5.3.3.2 Simulação de evolução de RNA “com herança de conhecimento”

1. DISCUSSÃO INICIAL Nesta segunda hipótese, todos os indivíduos herdaram matrizes

de pesos já evoluídos nos seus ascendentes, pelo menos parcialmente. O termo parcialmente se justifica pois, no caso em que um descendente teve seu número de neurônios da camada intermediária aumentado em relação ao indivíduo que lhe deu origem, somente a parcela da matriz que dimensionalmente foi trabalhada por este indivíduo conterá pesos já “evoluídos” e portanto conhecimento a ser transmitido. A parte da matriz “não treinada” conterá apenas pesos com valores aleatórios e espera-se que o conjunto dos pesos “evoluídos”, de fato tenha influência no processo evolutivo.

Sugere-se que esta experimentação é meramente ideal e indica que uma espécie transmitiria aos descendentes todo o conhecimento armazenado pelos antecedentes, que, por

sua vez, aumentá-lo-iam com novos conhecimentos durante sua existência.

2. PONTOS DESTACADOS

Descreve-se na sequência os passos mais importantes da implementação executada.

Na primeira geração as redes tiveram seu número de neurônios escondidos extraídos do mesmo conjunto H' já referido. As matrizes de pesos entre as camadas de entrada, intermediária e saída também tiveram inicialmente seus valores atribuídos de forma aleatória, no intervalo $[0,1]$. Então as 15 redes desta primeira geração foram treinadas por 150 épocas, com os 30 padrões iniciais da Tabela 5.3, medindo-se ao término da última época os erros dos vetores de saída, em relação aos valores desejados. Com a ajuda dos inversos destes erros construiu-se os valores de aptidão relativos de cada rede da população e, via operadores do AG, gerou-se a segunda população de redes.

Neste ponto ocorre a diferença fundamental em relação ao processo de evolução *sem herança*, descrito no item precedente. Enquanto naquela metodologia as matrizes de pesos das conexões sinápticas entre os neurônios de entrada, intermediários e de saída, desta segunda geração de redes, eram novamente obtidos aleatoriamente, como feito na partida da primeira geração, neste processo de evolução *com herança* as novas redes geradas pelo AG *herdam* não só os números de neurônios intermediários que resultaram em melhores valores de aptidão, mas também as matrizes de pesos já treinados na primeira geração. Esta herança, como já apontado, não é completa, devido à própria dinâmica da metodologia.

Para fixar idéias, imagine-se que o número de neurônios escondidos da primeira rede da segunda geração resulta da média inteira (arredondada, se necessário) dos neurônios da quinta e da décima segunda rede da primeira geração, com 10 e 24 neurônios, respectivamente. A rede em foco, isto é, a primeira da segunda geração, terá pois $(10+24)/2 = 17$ neurônios intermediários e irá ocupar o lugar da primeira rede da primeira população, quando esta população for substituída pela nova geração. Ora, a rede substituída tinha apenas 2 neurônios intermediários! Mas as duas matrizes de pesos sinápticos da rede substituída, *já foram treinadas durante 150 épocas na primeira geração*, farão parte integrante das matrizes maiores, da nova rede gerada, o que, em tese, tornará mais eficiente o treinamento do conjunto, uma vez que, talvez, apenas a parte restante deverá ser trabalhada.

Sugere-se que este mecanismo simule a passagem de parte do conhecimento armazenado pela geração ascendente à descendente, assim como nas espécies mais evoluídas os indivíduos captam de seus genitores, através da educação e da convivência, alguns conhecimentos por eles já dominados. Neste sentido, este mecanismo anexado ao AG, torna-o mais biologicamente inspirado que o anterior, onde apenas a aptidão advinda de melhores configurações da camada de neurônios escondidos era herdada de geração em geração.

Tabela 5.10: Evolução das RNA ao longo de 6 gerações e 150 épocas, *com herança*.

Rede	Geração 1		Geração 2		Geração 4		Geração 6	
	Cam.H	Erro	Cam.H	Erro	Cam.H	Erro	Cam.H	Erro
1	2	26.001	9	7.066	11	4.306	12	3.939
2	4	12.319	15	7.068	13	3.498	13	2.441
3	6	17.539	14	7.946	14	3.773	14	2.576
4	8	10.103	13	6.417	12	3.379	12	2.366
5	10	12.715	10	7.055	13	4.260	13	2.499
6	12	15.519	10	8.108	15	4.217	13	2.621
7	14	10.448	14	6.486	15	3.837	12	4.072
8	16	10.889	16	6.330	10	5.346	15	2.846
9	18	39.928	16	7.175	14	3.754	14	2.162
10	20	53.485	10	8.920	15	4.619	14	2.951
11	22	55.198	10	10.119	12	5.516	14	4.126
12	24	89.994	14	14.065	12	7.133	13	2.816
13	26	89.998	16	15.503	12	6.304	15	4.046
14	28	89.999	6	12.114	15	5.214	14	4.342
15	30	89.997	10	9.762	16	4.873	12	3.854
Erro Médio		41,61		8,94		4,67		3,18
Desv.Padr.		33,59		2,88		1,07		0,78

3. RESULTADOS TÍPICOS

No exemplo em pauta o processo se repete na evolução da segunda para a terceira geração e assim até a sexta.

Tabulou-se em 5.10 os erros obtidos nas gerações pares, além dos da primeira, com os respectivos números de neurônios gerados pelo AG.

Uma comparação da Tabela 5.10 com a 5.6 proporciona observações interessantes, como:

1. Na primeira geração os erros fornecidos pelas diferentes redes são muito semelhantes, tanto em nível de valores finais, quanto da média e desvio padrão do conjunto, que praticamente coincidem.

Os erros da segunda geração mostram grande melhora de performance com relação ao erro médio e ao desvio padrão de toda a população, caindo de 23,26 e 27,24, na primeira, para 8,94 e 2,88, respectivamente. Na geração 4 há novamente grande diferenciação do nível de erros, com vantagem marcante para as redes *com herança*, isto é, de 13,26 e 4,74 contra 4,67 e 1,07 para a média e desvio padrão respectivos. Na geração 6, última testada tanto na hipótese *sem herança* como na *com herança*, verifica-se, da mesma

Tabela 5.11: Número de saídas corretas na fase de treinamento das redes, *com herança*.

Rede	Geração 2				Geração 4				Geração 6			
	Épocas				Épocas				Épocas			
	10	50	100	150	10	50	100	150	10	50	100	150
1	10	23	28	29	29	29	29	29	29	29	29	29
2	29	29	29	29	29	29	30	30	30	30	30	30
3	21	28	29	29	30	30	30	30	30	30	30	30
4	29	29	29	29	29	29	30	30	30	30	30	30
5	27	29	29	29	29	29	29	29	30	30	30	30
6	10	24	28	28	29	29	29	29	29	29	30	30
7	29	29	29	29	29	29	29	29	29	29	29	29
8	29	29	29	29	29	29	29	29	29	29	29	30
9	0	28	29	29	29	29	29	29	30	30	30	30
10	6	10	26	29	29	29	29	29	29	29	30	30
11	6	11	26	28	29	29	29	29	29	29	29	29
12	0	2	10	25	18	28	29	29	29	29	29	30
13	0	0	10	23	29	29	29	29	29	29	29	29
14	0	0	10	27	29	29	29	29	29	29	29	29
15	0	7	22	28	29	29	29	29	29	29	29	29

forma que nas anteriores, a melhoria conseguida com a simulação da “transmissão” do conhecimento conseguido: O erro médio é 12,67 contra 3,18 e desvio padrão 2,63 contra 0,78.

- Note-se também que, nos dois paradigmas, há queda monotônica do erro médio à medida que se avança nas gerações. No caso onde não há “herança”, o melhor nível de acertos se deve à escolha de redes de melhor topologia, com a concorrência do AG. No caso da implementação da “herança”, além do fator acima, junta-se o aproveitamento, pelas redes geradas, do treinamento providenciado pelas geradoras.
- A indicação de convergência do número de neurônios intermediários nas redes *sem herança*, parece mostrar que há um atrator situado no entorno de 10 neurônios.

Similarmente ao caso anterior, montou-se a Tabela 5.11 para mostrar os acertos nas gerações pares após 10, 50, 100 e 150 épocas de treinamento.

Comparando as Tabelas 5.10 e a 5.11 também se encontra o fenômeno já frisado na caso da metodologia “sem herança”. Note-se que a rede 1, com 9 neurônios escondidos na segunda geração, substitui a rede 1, com 2 neurônios, na primeira geração. Nesta primeira geração a rede 1 tivera erro de 26,01, relativamente alto em relação às 8 primeiras (e melhores) redes. Como consequência, a rede 1 da segunda geração, apesar de ter “partido” no treinamento com número de neurônios mais favorável, herdou

poucos pesos já treinados da primeira geração, o que implicou em baixo nível de acertos até a época 50 (23 acertos), tendo melhorado na 100 e atingido 29 acertos na última época treinada.

A segunda rede da geração 2 substitui a segunda rede da geração 1, cujo erro era menor que a metade do da primeira rede (12.319 contra 26.001) e já conseguiu acertos quase totais (29 corretos em 30 possíveis), logo a partir da 10ª época, portanto com baixo treinamento.

No caso da terceira rede da geração 2, também houve necessidade de treinamento maior, até a 50ª época, o que de certo modo já se podia antecipar pelo valor do erro da rede 3 da primeira geração, relativamente grande em relação às vizinhas.

Por outro lado, olhando-se as últimas redes da segunda geração, como a 12ª, 13ª, 14ª e 15ª, constata-se que todas tiveram número de acertos nulo ou inferior a 2 até a 50ª época, exceto a 15ª rede, que teve o baixo score de 7 acertos. Também, as redes que mais acertos forneceram foram as agraciadas com número de neurônios mais adequado, em relação às respectivas redes da primeira geração. Note-se que, em consonância com a hipótese aqui levantada, estas últimas 4 redes requiseram treinamento acentuado nas primeiras épocas, devido ao fato de terem substituído redes pouquíssimo treinadas da primeira geração (onde o erro foi, em todas as apontadas, próximo a 90).

A geração 4 mostra acertos quase totais já a partir da 10ª época, para todas as redes, exceto a de número 12, que, entretanto, atinge 28 acertos em 30, já na 50ª época.

Na geração 6 todas as redes, desde a 10ª época, acertaram 29 saídas em 30, tendo algumas, como a 2ª, 3ª, 4ª e 9ª acertado as 30 saídas possíveis.

Nota-se ainda que o AG levou as redes de um número de neurônios médio de 16, na primeira geração, para um valor pouco abaixo de 14 na segunda e praticamente se estabilizou em torno de 13 na quarta e sexta gerações. No caso das redes *sem herança*, este parâmetro, a partir da geração 4, tendeu para 10.

VERIFICAÇÃO

Similarmente à tabela 5.8, montou-se a 5.12, com o percentual de acertos de cada rede que trabalhou “com herança”. Estes valores foram obtidos com os 20 últimos vetores da amostra (Tabela 5.3), não submetidos às mesmas em tempo de treinamento e usados para verificar a capacidade de extrapolação das redes.

A última linha da Tabela 5.12 indica que houve ganho percentual de acertos em 2/3 das redes treinadas *com herança*, embora também neste caso não se tenha construído o sistema ou tratado os dados iniciais com cuidados especiais para que se tivesse aderência maior entre os resultados obtidos e os corretos.

Tabela 5.12: Percentuais de acerto de cada rede, ‘em tempo de verificação’, *com herança*.

<i>Rede</i>	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Cam. H	12	13	14	12	13	13	12	15	14	14	14	13	15	14	12
% Acertos	65	70	70	65	70	70	65	70	75	65	70	65	70	65	70
% Acréscimo	0	5	5	0	5	5	5	5	10	0	20	0	30	0	5

5.4 PROPOSTA DE MÉTRICA PARA IAE

Neste Capítulo se observou que o paradigma de Computação Evolucionária denominado Algoritmo Genético pode ser empregado de forma a retratar mais ou menos fielmente os fenômenos naturais em que foi inspirado. Mostrou-se que, como no problema dos Quadrados Mágicos, o emprego deste paradigma não dá bons resultados, talvez porque se tenta simular um fenômeno que já está em seu limite evolucionário.

No segundo problema tratado, consorciando AG com RNA se obteve bons resultados, que melhoraram ainda mais quando a simulação incluiu o processo de passagem de aprendizado entre gerações.

Julgou-se importante ter uma possibilidade de poder obter o “quantum” de variação na Inteligência, guardadas as restrições citadas neste trabalho, entre os sistemas de IA, já que usualmente, o conhecimento de um fenômeno é mais completo se o mesmo puder ser expresso por medidas.⁷

Na seção 2.4 foi feito um estudo sobre as possibilidades de tais medidas, nos paradigmas de IAS e de IAC. Faz-se aqui resumidamente discussão similar para IAE.

No texto do Capítulo 2 se mostrou que a simulação da Inteligência via *processos mentais*, que supostamente reproduzem-na, não dão ainda vislumbre de formas de medição factíveis.

Por outro lado, conceituando-a como *faculdade que possibilita solucionar problemas* [CHE 85], tem-se a chance da construção de “funções de aptidão” que fornecem a gradação da qualidade das soluções conseguidas e, em consequência, do nível de inteligência nelas embutido. Neste sentido a Inteligência é diretamente dependente do problema atacado. Aí se reconhece o mérito da hipótese levantada por Gardner [GAR 94], das inteligências múltiplas, onde cada componente da ênupla formada é dirigida a um tipo de problema bem específico.

Caracterizado o problema e definida a função de aptidão que forneça as comparações entre as soluções possíveis, pode-se, para um paradigma de IAE escolhido, conseguir métricas significativas com respeito à variação do grau de Inteligência entre as implementações construídas. Deve-se atentar cuidadosamente, entretanto, para os aspectos referentes à ordem completa ou parcial (Em 2.4.4).

⁷“You can’t control, what you can’t measure” - Tom de Marco.

No caso dos AG analisados neste Capítulo, o desenvolvido para encontrar RN de arquitetura mais adequada teve função de aptidão definida como o somatório das “distâncias” entre as componentes do vetor resposta fornecido pelo sistema e as do vetor desejado. Para esta situação, mostrou-se que o AG “com adoção de herança de conhecimento” entre as gerações suplantou o AG “sem herança”. De fato, após 150 épocas de treinamento, já na 4ª geração, as saídas eram corretas em 29 das 30 possíveis (Tabela 5.11) para todas as redes. Em contrapartida, com 6 gerações “sem herança”, apenas 6 redes entre 15 forneceram 29 saídas corretas (Tabela 5.7). Neste caso a variação do número de gerações entre os sistemas em análise se configura como uma métrica adequada para medida de QI.

Capítulo 6

CONCLUSÃO

I didn't know that I didn't know. Now I know that I don't know.

O propósito básico inicial deste trabalho constituiu-se em estudar a inspiração biológica inserida nos diversos paradigmas de CE, mostrando que se pode tornar estas metodologias, em certos casos, mais coerentes com o funcionamento do processo biológico (sobretudo o evolutivo) e, com esta adequação, obter resultados úteis na busca de sistemas inteligentes.

Mostrou-se que a própria concepção do que seja *sistema inteligente e inteligência* é problemática, podendo ser abordada de inúmeras maneiras, muitas delas até antagônicas.

As visões de Darwin e de Prigogine sobre os mecanismos intervenientes na evolução de seres vivos foram mostradas, sob os aspectos que se julgou mais interessantes, quanto à possível aplicação nos paradigmas de CE.

Aplicou-se o fato, tido como aparente em algumas situações da Natureza, em que as gerações parecem adotar um processo seletivo onde os indivíduos tendem a “herdar” o conhecimento adquirido pelos ancestrais, através de um mecanismo indireto [BAL 96]. Nesta concepção, os seres que mais aprendem, devido a características próprias, tendem a legar este conhecimento, pois terão mais possibilidade de sobrevivência e procriação. Como que se manifesta uma evolução com herança de conhecimento, entre as gerações.

Com este indicativo, dois exemplos foram simulados, utilizando o paradigma de CE mais amplamente empregado, a saber o AG. No primeiro caso, procurou-se empregar o AG para solucionar o problema conhecido como Quadrado Mágico. Ficou patente que esta aplicação não se coaduna bem com o ferramental do AG, parecendo mostrar que certas espécies atingiram grau evolutivo onde os operadores conhecidos da evolução não são mais efetivos.

No segundo exemplo consorciou-se o AG com o paradigma de IAC, adotando-se RNA diretas treinadas com retropropagação, para mostrar que a simulação do efeito supra-mencionado traz vantagens claras em termos de velocidade de evolução.

insp

Entretanto, o processo de evoluir sistemas inteligentes traz à baila o problema da comparação dos graus de inteligência alcançados. Aproveitando as pesquisas feitas por psicólogos, biólogos, fisiologistas, etc. na quantificação da inteligência, um esforço foi feito para estudar e propor direções por onde se poderia obter avanços nesta pesquisa.

Os estudos sobre a evolução (ver Capítulo 3) indicam que a Inteligência, para a acepção de emergência cerebral [SEA 84], existe na Terra há poucas eras, na escala geológica. Mas o mecanismo engendrado pelo DNA, que pode criar, perpetuar e evoluir a vida existe há uns 4,5 bilhões de anos, o que faz esta acepção de Inteligência retroagir à época do aparecimento da vida em nosso planeta.

Olhando esta forma extraordinária que a Natureza criou para solucionar o problema de sustentar e desenvolver a vida sobre a Terra, talvez o maior problema após o do surgimento do próprio universo, os pesquisadores da área da Informática adaptaram o mecanismo da evolução das espécies para resolver casos de busca de soluções ótimas, ou pelo menos aproximadas, ainda insolúveis pelos métodos clássicos disponíveis. Diversos paradigmas foram sugeridos, criando-se a área de estudos rotulada de CE.

A CE é fortemente dependente de grande quantidade de cálculos, o que implica na necessidade da utilização de computadores para as aplicações práticas. Nenhum humano, não importando quão “inteligente” ela ou ele seja, seria capaz de resolver problemas tão complexos ou executar, durante sua vida, os cálculos necessários nos métodos de CE. Como então explicar que uma máquina “idiota” - o computador - pode ter uma performance tão estupenda na consecução deste objetivo, desafiando assim as habilidades humanas em fazer o mesmo? Fugindo da definição de inteligência como um conceito puro e abstrato e olhando-o como uma potencialidade para resolver problemas, tem-se alternativamente porém que levar em consideração outro fator: a “capacidade de trabalho”.

Sugere-se que a inteligência precisa “trabalhar”, para ser efetiva no atendimento dos objetivos que demandam sua aplicação [FAL 01a]. Em outras palavras, acredita-se que uma “grande inteligência” é de pouca utilidade para solucionar os problemas da vida, se permanecer em um estado de ‘dormência’ ou de ‘preguiça’. Talvez se faça mais com uma inteligência não tão brilhante, mas muito ativa. Quando se vê um computador digital executando cálculos complicados, embora conhecendo-o em detalhe, dificilmente se atenta para o fato de que as operações atômicas elementares (simuladas apenas com os algarismos 0 e 1) que embasam seu trabalho são muito simples e, individualmente, requerem pouca inteligência para serem entendidas. O que verdadeiramente está em jogo é sua velocidade incrível com que tais operações elementares são executadas. Conseqüentemente, pouca quantidade de inteligência empregada repetidas vezes, em alta velocidade pode fornecer, em um intervalo de tempo relativamente curto, uma boa solução de um problema muitas vezes totalmente inalcançável pelo mais inteligente ser humano (o que não desmente o fato de inteligências geniais poderem, em lampejos, resolver problemas extraordinários).

A Figura 6.1 ilustra este ponto. Embora o Sistema 1 seja menos inteligente que o Sistema 2 (a abscissa I_1 é bem menor que a I_2), ele tem uma “capacidade de trabalho”

¹ deve maior (a ordenada W_1 é bem maior que a W_2).

Por construção, se tem, em valores modulares:

$$I_1 = W_2$$

e

$$W_1 = I_2$$

o que resulta no mesmo produto final:

$$P_1 = P_2$$

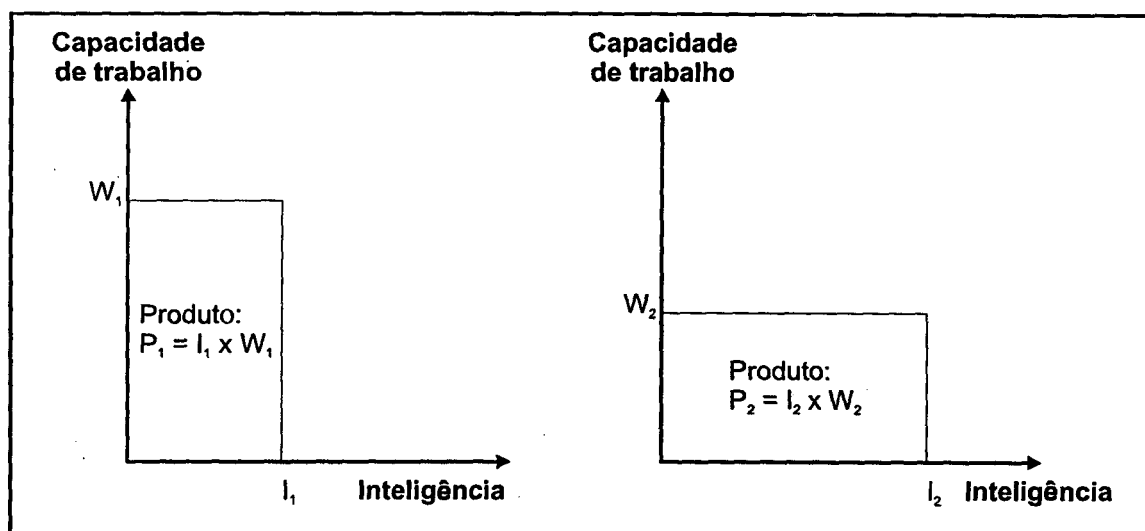


Figura 6.1: Os fatores *inteligência* e *trabalho*.

Estes fatos são há muito conhecidos pela sabedoria popular. Alguns exemplos são os ditados “o gênio é feito de 90% de transpiração e de 10% de inspiração”, “água mole em pedra dura tanto bate até que fura”. As notáveis conquistas de pequenos insetos como as abelhas, as formigas já citados no Capítulo 3, ou mesmo de mamíferos como os castores, que, com pequenas colaborações individuais, conseguem feitos admiráveis, provam factualmente, mais uma vez, a veracidade desta assertiva.

Embora os métodos empregados na CE não garantem que se depare com a solução ótima global do problema em questão, pelo menos uma solução próxima do ótimo pode ser encontrada. A metodologia da CE deve ser empregada em *problemas complexos*. Aqui o termo *complexos* não se refere à dificuldade de compreensão do problema, mas ao imenso espaço de soluções a ser vasculhado, e isto com pouca ou nenhuma indicação que possa ser utilizada para direcionar a busca. Esta característica torna a força bruta do computador mais poderoso, sem serventia para varrer completamente a área de busca. Os problemas

¹O conceito *capacidade de trabalho* e sua interação indicada com a inteligência devem ser entendidas apenas em sentido amplo e metafórico.

de *satisfabilidade* (validação das regras de SE) são exemplo de onde aparecem este tipo de complexidade.

Há ainda métodos não baseados na evolução, mas em outros fenômenos observados na Natureza, como o da têmpera artificial, conjuntos difusos, fractais, sistemas complexos. Os avanços conseguidos nas áreas abrangidas pelos campos aqui englobados pelo nome de Computação Natural (Ver Figura 4.1) autorizam e encorajam uma incursão exploratória em regiões que talvez possibilitem a abertura de horizontes, como o da medição de QI para máquinas.

Apesar das metodologias até agora trabalhadas em CE serem projetadas para operar com apenas uma espécie, convivendo com as variações de um único meio, deve-se levantar a hipótese de que seja possível adaptar algum destes paradigmas para funcionar com uma mesma espécie, em diferentes meios, pois em CE, por hipótese, as várias facetas da Inteligência serão consequência direta dos estímulos produzidos pelo meio e de fatores evolucionários, como recombinação, seleção e mutação.

6.1 EPÍLOGO

6.1.1 Propostas para novas pesquisas

- Simulação de evolução com *herança parcial* de conhecimento inter-gerações.
Este experimento simularia a hipótese de “indivíduos herdarem algum conhecimento dos ancestrais”, com interveniência, para possibilitar e incrementar o processo evolutivo, da não sincronia entre as renovações ocorridas entre os mesmos. No caso apresentado em 5.3.3, os cromossomos que permanecem na população continuam com os pesos já trabalhados, isto é, supõe-se que seu conhecimento já foi “somatizado”. Os indivíduos que adentram à população começam com pesos aleatórios: Os novos iniciam a vida naquela geração sem nenhum conhecimento.
- Simulação de evolução usando AG com outros paradigmas de RNA, nos moldes do sistema proposto em 5.2, comparando os resultados com o de redes diretas, treinadas com retropropagação.
- Simulação da aprendizagem mediante a convivência dos indivíduos, em *gerações não sincronizadas*, usando os conceitos de *vida artificial*.
- Padronização dos termos e conceitos de IA com a proposição de uma taxonomia mais formalizada.
- Pesquisa para definições e metodologias de aplicação de métricas para comparações entre sistemas de IA;
- Sistema simuladores e aplicações que adotem outras inspirações biológicas nos diversos paradigmas de IA, implementados isoladamente ou hibridizando diversos paradigmas;
- Sistemas evolutivos que considerem os comportamentos individuais inspirados nas teorias de jogos, uma vez que parece haver evidências da existência não apenas de interações

aleatórias, mas de estratégias definidas entre os componentes populacionais.

6.1.2 Palavras finais

Este Capítulo conclusivo apresenta idéias sobre a possibilidade de estender um pouco além das atuais fronteiras o campo abrangido pela pesquisa atualmente feita na área geralmente conhecida pelo nome genérico de Computação Inteligente [BEZ 94]. Esta área está crescendo tanto em termos de pesquisa quanto à disponibilidade de produtos operacionais já comercializados. Parte-se do princípio de que uma métrica que permitisse a comparação dos níveis de inteligência conseguidos pelas “máquinas inteligentes”, sejam elas sistemas de software ou de hardware, seria factível embora as medições com os índices adotados não sejam possuidores de “ordem completa”, a não ser talvez entre sistemas que adotem a mesma metodologia de implementação.

Com a pesquisa de diversas tecnologias para construção de computadores - cite-se as que adotam a física quântica e a de processadores biológicos - a acepção de Turing do computador digital como máquina inteligente deve ser repensada [COH 01].

Quanto à concepção de inteligência, assim como de muitos outros conceitos usados com frequência como: Computação Inteligente, máquinas inteligentes, capacidade de trabalho e tantos outros, deve ser feito um maior esforço de definição formal, para que os trabalhos da área sejam comparáveis em bases mais sólidas.

Até que isto aconteça, admitindo-se que seja feito um dia, o conjunto formado pelas medidas de QI das máquinas não poderia ser aceito como tendo ordem completa, pois ainda não se estabeleceu uma forma para comparar os elementos básicos dos paradigmas envolvidos. Entretanto, acredita-se que o conceito de inteligência isolado é muito abstrato para ser medido objetivamente. Para fazer sentido, ele deveria ser associado a determinada tarefa executada em algum ambiente definido.

Hoje é perceptível a tendência da literatura em mostrar mais que um tipo de inteligência e estas diferenças se referem a habilidades bem mais distintas e específicas que o entendimento de algum conceito. Se comparados um sistema computacional com um ser humano, talvez se possa dizer que o hardware da máquina seria o código genético do humano, enquanto o software seria o homólogo do conhecimento adquirido (educação, treinamento, etc.). R. Dawkins propõe, neste contexto, o componente *memético* [DAW 76], a unidade de informação residente no cérebro. O meme (pode ser uma idéia, um tom, uma forma, etc.) seria nas estruturas mentais o que o gene é em um organismo vivo. Assim, como os humanos (e animais?), talvez os computadores tenham diferentes inteligências.

As atividades de pesquisa em Ciência da Computação e em outras áreas tecnológicas geralmente tendem a se aproveitar de inspirações em leis físicas ou matemáticas, mas os frutos já colhidos nos diversos campos de IA demonstram que a Natureza, e em especial os fenômenos da vida, podem trazer boas contribuições. A dificuldade está em enxergar as sugestões, o que é similar ao trabalho do pesquisador quando se lança em áreas não dominadas, tentando alargar as fronteiras da ciência. Este esforço é amiúde acompanhado da angústia proveniente da aventura em ambiente desconhecido, da incerteza da obtenção de

resultados relevantes, das cobranças engendradas pela própria consciência e pelo ambiente. Aí se faz mister lembrar o lema latino “labore et constantia”², já adotado como divisa, em 1549, no brasão de Christophe M. Plantin, insigne impressor.

Apesar de existirem linhas filosóficas que diminuem o papel do trabalho ([LAF 80], citando o modo de vida de civilizações como a Romana e a Grega ([VEY 89]), onde ele era relegado a estrangeiros e escravos, a visão do mundo parece indicar que o par ‘inteligência-trabalho’ gera muitos e bons filhos.

²Trabalho e constância.

Capítulo 7

ANEXO

“É melhor aproximadamente agora que exatamente nunca”

7.1 DADOS MÉDICOS REUMÁTICOS ORIGINAIS

Disponibiliza-se aqui, em forma textual, os dados trabalhados pelo algoritmo implementado, utilizando AG e RNA, no item 5.3.2 e seguintes. A Tabela 5.3 é reproduzida, agora de forma codificada e completa ¹ nas Tabelas 7.1 e 7.2. Por questões de espaço, os termos foram abreviados, com seus significados expostos nas Tabelas 7.3 e 7.4.

¹ Isto é, com todos os 50 vetores envolvidos: no treinamento os 30 primeiros, e na verificação os 20 últimos.

Tabela 7.1: Tabulação dos dados obtidos em clínica médica.

Ca	G	Ag	L	S	D	O	P	LI	RE	C	A	M	B	T	Y	R	N	H	J	Diagn.
1	m	30	y	y	y	li	y	ab	mo	mo	n	n	n	n	n	n	n	n	n	An.Spon.
2	w	23	n	n	n	no	n	ab	mo	n	y	n	n	n	n	y	n	n	n	Art.Gout
3	m	30	n	n	n	li	n	mo	mo	n	y	y	y	y	y	y	n	n	n	Art.Gout
4	m	70	n	n	n	li	n	ab	mo	n	n	n	n	y	n	y	n	n	n	Art.Gout
5	w	63	n	n	n	no	n	mo	i	mo	n	n	n	n	n	y	n	n	n	Rh. Art.
6	m	59	n	n	n	li	n	v.i.	v.i.	i	y	n	n	y	y	y	n	n	n	Art.Gout
7	w	61	n	n	n	li	n	mo	v.i.	n	y	n	n	n	y	y	n	n	n	Rh. Art.
8	m	21	y	n	y	no	y	mo	i	i	n	n	n	n	n	n	n	p	n	An.Spon.
9	w	56	y	y	n	li	y	i	v.i.	i	y	y	n	n	y	y	n	n	n	Rh. Art.
10	w	72	n	n	n	li	n	v.i.	ab	mo	y	y	n	n	y	y	y	n	n	Rh. Art.
11	m	24	y	y	y	li	y	mo	i	n	n	n	n	n	n	n	n	p	n	An.Spon.
12	w	77	n	n	n	li	n	l	mo	n	y	n	n	n	y	y	n	n	n	Rh. Art.
13	m	57	n	n	n	li	n	v.i.	ab	n	y	n	n	n	y	y	n	n	n	Art.Gout
14	w	74	n	n	n	li	n	i	ab	l	y	y	n	n	y	y	n	n	n	Rh. Art.
15	w	35	n	n	n	no	n	n	n	n	n	n	n	n	n	n	n	n	n	Normal
16	w	21	n	n	n	n	l	v.i.	n	n	n	n	n	n	n	n	n	n	n	An.Spon.
17	m	46	n	n	n	li	n	m	m	n	y	n	n	y	n	y	n	n	n	Art.Gout
18	w	70	n	n	n	no	n	l	i	n	y	y	n	n	y	y	n	n	n	Rh. Art.
19	m	57	y	y	y	li	n	m	v.i.	m	y	n	n	n	n	y	n	p	y	An.Spon.
20	m	41	y	n	n	no	n	m	ab	n	y	n	n	n	y	y	n	p	n	An.Spon.
21	w	72	n	n	n	li	n	i	ab	m	y	y	n	n	y	y	n	n	y	Rh. Art.
22	m	59	n	n	n	no	n	l	i	n	y	n	n	y	y	y	n	n	n	Art.Gout
23	w	18	y	n	n	no	n	ab	m	m	n	n	n	n	n	y	n	p	n	An.Spon.
24	m	28	y	y	n	no	y	ab	m	l	n	y	n	n	n	n	n	p	n	An.Spon.
25	m	22	y	n	y	no	n	ab	i	n	n	n	n	n	n	n	n	p	n	An.Spon.

Tabela 7.2: Tabulação dos dados obtidos em clínica médica - (Continuação da Tabela 7.1).

Ca	G	Ag	L	S	D	O	P	LI	RE	C	A	M	B	T	Y	R	N	H	J	Diagn.
26	m	27	n	n	n	no	n	i	ab	n	n	n	y	n	n	y	y	n	n	Rh. Art.
27	m	40	y	y	n	no	n	l	i	i	n	n	n	n	n	n	n	p	n	An.Spon.
28	w	63	y	y	n	no	n	ab	ab	n	n	y	n	n	n	y	n	n	n	Rh. Art.
29	m	69	n	n	n	li	n	m	m	m	y	n	n	n	n	y	n	n	n	Art.Gout
30	m	65	n	n	n	li	n	i	i	m	y	n	y	y	y	y	n	n	n	Art.Gout
31	m	32	y	y	y	no	n	ab	i	n	n	n	n	n	n	n	n	p	n	An.Spon.
32	m	50	n	n	n	no	n	i	i	n	y	y	y	y	n	y	n	n	n	Art.Gout
33	m	38	y	n	n	no	y	m	i	n	n	y	n	n	n	n	n	p	n	An.Spon.
34	w	54	n	n	n	li	n	l	i	n	y	y	n	n	y	y	n	n	n	Rh. Art.
35	m	55	n	n	n	li	n	l	m	n	y	y	n	n	y	y	n	n	n	Rh. Art.
36	m	39	y	y	n	no	y	ab	i	i	n	y	n	n	n	y	n	p	n	An.Spon.
37	m	38	n	n	n	no	n	i	m	n	y	n	y	y	y	y	n	n	n	Art.Gout
38	m	57	n	n	n	li	n	m	ab	n	n	n	y	y	n	n	n	n	n	Art.Gout
39	w	64	n	n	n	li	n	m	i	n	y	n	n	n	y	y	n	n	n	Rh. Art.
40	m	70	n	n	n	no	n	i	i	n	y	n	n	n	y	y	n	n	n	Rh. Art.
41	w	36	n	n	n	li	n	i	m	m	y	n	n	n	y	y	n	n	n	Rh. Art.
42	m	36	y	n	n	no	n	m	i	n	n	n	n	n	n	n	n	p	n	An.Spon.
43	w	48	n	n	n	no	n	i	i	n	n	y	n	n	n	y	n	n	n	Rh. Art.
44	w	24	n	n	n	li	n	ab	ab	n	y	n	n	n	y	y	n	n	n	Rh. Art.
45	m	69	y	n	n	no	n	l	i	n	y	n	n	n	y	y	n	n	n	Art.Gout
46	w	32	y	y	n	li	y	l	i	n	n	y	n	n	n	n	n	n	n	An.Spon.
47	m	63	n	n	n	li	n	i	m	n	y	y	n	n	y	y	n	n	n	Rh. Art.
48	w	39	n	n	n	no	n	m	i	n	n	y	n	n	n	y	n	n	n	Rh. Art.
49	w	33	y	y	n	li	n	i	m	n	n	n	n	n	n	n	n	p	n	An.Spon.
50	m	33	y	n	n	no	n	ab	m	m	n	n	n	n	n	y	n	n	n	Art.Gout

Tabela 7.3: Significado das abreviações utilizadas na Tabela 7.1.

<i>Abreviação</i>	<i>Texto Original</i>	<i>Português</i>
A	Arthritis	Ver Tabela 7.4
ab	Absent	Sintoma ausente
Ag	Age	Idade
An.Spon.	Ankylosing Spondylitis	Ver Tabela 7.4
Art.Gout	Arthritis of Gout	Ver Tabela 7.4
B	Bursitis	Ver Tabela 7.4
C	Computed tomography/Scintigraphy evidence	Ver Tabela 7.4
Ca	Case	Caso
D	Spinal column deformity	Ver Tabela 7.4
Diagn.	Diagnostic	Diagnóstico
G	Sex	Sexo
H	HLA-B27	Ver Tabela 7.4
i	Important	Importante
J	Joints deformity	Ver Tabela 7.4
L	Lumbar pain	Ver Tabela 7.4
l	Light	Leve (pouco importante)
LI	Laboratory/Inflammation	Ver Tabela 7.4
li	Limited	Limitada (mobilidade)
M	Morning Stiffness	Ver Tabela 7.4
m	Male	Masculino
mo	Moderate	Moderado
N	Rheumatoid Nodules	Ver Tabela 7.4
n	Negative	Negativo
no	Normal	Normal
O	Mobility	Ver Tabela 7.4
P	Sacroiliac pain a examination	Ver Tabela 7.4
p	Positive	Positivo
R	Arthralgia	Ver Tabela 7.4
Re	Radiological evidence	Ver Tabela 7.4
Rh. Art.	Rheumatoid Arthritis	Ver Tabela 7.4
S	Spinal column stiffness	Ver Tabela 7.4
Y	Synovite	Ver Tabela 7.4
T	Tophus	Ver Tabela 7.4
v.i.	Very important	Muito importante
w	Woman	Feminino
y	Yes	Sim

Tabela 7.4: Descrição dos diagnósticos da Tabela 7.1.

<i>Inglês</i>	<i>Português</i>	<i>Descrição</i>
Lumbar pain	Dor lombar	Dor na baixa região lombar, isto é, na área entre o par de costelas mais baixo e o topo da pelve.
Spinal column stiffness	Enrijecimento da coluna vertebral.	
Spinal column deformity	Deformação na coluna vertebral.	
Mobility	Mobilidade	Grau de mobilidade do paciente.
Sacroiliac pain a examination	Dor na articulação do sacro e íliaco	Ossos que contribuem para formação do esqueleto ósseo da bacia, região lombar inferior.
Laboratory/Inflammation	Laboratório Inflamação	Testes
Radiological evidence	Evidência radiológica	Testes de Raios X.
Computed tomography/ Scintigraphy evidence	Tomografia computadorizada/ Evidência em cintilografia	Exame com aparelho de Raios X especial computadorizado, que registra imagens de planos predeterminados de órgãos, diminuindo interferência de outros planos. - Exame de órgãos internos mediante a utilização de isótopos radioativos.
Arthritis	Artrite	Deformidade e/ou enrijecimento crônico e progressivo de uma ou mais articulações.
Morning stiffness	Rigidez matinal	Dor e/ou rigidez nas costas, sobretudo no período matinal, posterior ao levantar.
Bursitis	Bursite	Inflamação de bolsa: estrutura protetora entre tendão muscular e outro tendão ou osso, geralmente permitindo que o tendão ou o músculo deslize sem muito atrito.

Tabela 7.5: Descrição dos diagnósticos da Tabela 7.1 - (*Continuação da Tabela 7.4*).

<i>Inglês</i>	<i>Português</i>	<i>Descrição</i>
Tophus	Tofo	Solidificação de cristais de ácido úrico, que se depositam nos tecidos moles subcutâneos, formando nódulos de aproximadamente 1cm .
Synovite	Sinovite	Inflamação aguda ou crônica da membrana sinovial: reveste a cápsula das articulações (envelope que contém o líquido sinovial, lubrificante das superfícies articuladas).
Arthralgia	Artralgia	Dor em uma ou mais articulações.
Rheumatoid Nodules	Nódulos reumáticos	Protuberâncias de tecido que se formam sob a pele, geralmente em áreas próximas a ossos, como o cotovelo, mas possível também em órgãos internos.
HLA-B27	Iniciais de Human Lymphocyte Antigen B27	Exame de sangue para detecção da presença do antígeno HLA-B27. Um teste positivo de HLA-B27 é fortemente associado à presença de An.Spon. (ver abaixo).
Joints deformity	Deformidade em articulações	Deformidades nas articulações, observáveis sobretudo nas das falanges das mãos.
Diagnostics	Diagnósticos	Diagnósticos dados aos casos analisados.
Ankylosing Spondylitis	Espondilite anquilosante	Inflamação de uma ou mais vértebras. Doença crônica que afeta as junções entre as vértebras dorsais, as junções da espinha vertebral com a pelve, podendo ocasionar soldagem entre as partes.
Arthritis of gout	Artrite gotosa	Inflamação aguda de articulações, especialmente de pernas e pés, devido à deposição de cristais de ácido úrico, provocando geralmente ataque noturno repentino de dor severa, vermelhidão, inchaço e sensibilidade.
Rheumatoid Arthritis	Artrite reumática	Doença inflamatória crônica em múltiplas articulações e tecidos próximos, comumente ocasionando vários sintomas, como dores, febre, perda de apetite, fraqueza.
Nothing	Nada	Paciente normal. Nenhum diagnóstico dado.

Referências Bibliográficas

- [AHO 98] AHOUSE, J. C. Darwin and the mind. **Boston Review**, [S.l.], v.1, apr/may, 1998.
- [AMA 94] AMABIS, J. A. **Fundamentos da Biologia Moderna**. São Paulo:Ed. Moderna, 1994.
- [ARA 93] ARANHA, M. L. A. **Filosofando - Introdução à Filosofia**. São Paulo:Moderna, 2. ed., 1993.
- [BÄC 93] BÄCK, T. An overview of evolutionary algorithms for parameter optimization. **Evolutionary Computation**, [S.l.], v.1, n.1, p.1-23, 1993.
- [BÄC 96] BÄCK, T. **Evolutionary Algorithms in Theory and Practice**. New York:Oxford University Press, 1996.
- [BAK 92] BAKER, G. L. **Chaotic Dynamics - an Introduction**. New York, 1992:Cambridge University Press, 1992.
- [BAL 96] BALDWIN, J. M. A new factor in evolution. **American Naturalist**, [S.l.], v.30, p.441-451, 1896.
- [BAR 01] BARRETO, J. M. **Inteligência Artificial no Limiar do Século XXI**. Florianópolis:Duplic Prest. Serviços, 2. ed., 2001. 324p.
- [BAY 98] BAYLY, P. V. et al. Spatial organization predictability and determinism in ventricular fibrillation. **Chaos**, [S.l.], v.8, p.103-115, 1998.
- [BEA 93] BEASLEY, D.; BULL, D. R. An overview of genetic algorithms - part 1, fundamentals. **University Computing**, 15(2):58-69, University of Cardiff, Cardiff, 1993.
- [BEL 93] BELEW, R. K. **Interposing an Ontogenic Model Between Genetic Algorithm and Neural Networks**, chapter Advances in Neural Information Processing (NIPS 5). Morgan Kaufmann, 1993. S. J. Hanson, J. D. Cowan and C. L. Giles.
- [BEN 76] BENSON, W. **New Recreations with Magic Squares**. New York:Dover Publications, 1976.
- [BEV 99] BEVILACQUA, R. et al. Estratégias adaptativas em sociedades de formigas. **Controle e Automação - Revista da SBA**, [S.l.], v.10, p.167-175, 1999.

- [BEZ 94] BEZDEK, J. C. **What is Computational Intelligence**, p.1–12. IEEE Press, 1994.
- [BÍB 87] BÍBLIA. **BÍBLIA. Português. Bíblia Sagrada. Tradução: Padre Antônio Pereira de Figueredo**. Rio de Janeiro, 1987. Encyclopaedia Britannica. Edição Ecumênica.
- [BIS 90] BISHOP, J. E. **Genome: The Story of the Most Astonishing Scientific Adventure of our Time**. Simon & Schuster, 1990.
- [BIT 98] BITTENCOURT, G. **Inteligência Artificial: Ferramentas e Teorias**. Florianópolis:UFSC, 1998.
- [BOH 51] BOHM, D. **Quantum Theory**. New York:Prentice-Hall, 1951.
- [BOO 54] BOOLE, G. **An Investigation of the Laws of Thought**. London:Walton & Maberly - Reprinted in 1958 by Dover, New York, 1854.
- [BOO 89] BOOKER, L. B.; GOLDBERG, D. E. Classifier systems and genetic algorithms. **Artificial Intelligence**, [S.l.], v.40, p.235–282, 1989.
- [BOO 97] BOOKER, L. B. et al. **Handbook of Evolutionary Computation**, v.Part C, chapterRecombination, p.C3.3:1–C3.3:27. Institute of Physics Pub. and Oxford University Press, Bristol, PA, 1997.
- [BRA 97] BRASIL, L. M.; DE AZEVEDO, F. M. Learning algortihm for connectionist systems. In: [S.N.], 1997. **Proceedings...** Temuco, Chile:Universidad de la Frontera, 1997. v.2, p.697–702.
- [BRA 99] BRASIL, L. M. **Proposta de Arquitetura para Sistema Especialista Híbrido e a Correspondente Metodologia de Aquisição de Conhecimento**. Florianópolis, Brasil:PGEEL - Universidade Federal de Santa Catarina, fev., 1999. Tese de Doutorado.
- [BRO 00a] BROOKSHEAR, J. G. **Ciência da Computação - Uma Visão Abrangente**. Porto Alegre:Bookman, 5. ed., 2000.
- [BRO 00b] BROWN, L. M. **Selected Papers of Richard Feynman**. EUA:World Scientific Publishing Company, Incorporated, 2000.
- [BUC 00] BUCHANAN, M. A. **Ubiquity**. Londres:Weidenfeld & Nicolson, 2000.
- [CAL 94] CALVIN, W. H. The emergence of intelligence. **Scientific American**, [S.l.], v.271, n.4, p.100–107, 1994.
- [CAP 83] CAPRA, F. **O Tao da Física**. São Paulo:Editora Cultrix, 1983.
- [CAR 95] CARPENTER, W. C. Training backprop neural nets. **AI Expert**, [S.l.], v.1, p.30–33, march, 1995.
- [CEL 91] CELLIER, F. **Continuous System Modling**. Berlin:Springer-Verlag, 1991.
- [CER 98] CERUZZI, P. E. **A History of Modern Computing**. Cambridge:MIT Press, 1998.

- [CHA 96] CHALMERS, D. **The Conscious Mind**. London:Oxford University Press, 1996.
- [CHE 85] CHERNIAK, E. **Introduction to Artificial Intelligence**. Massachusetts:Addison-Wesley, 1985.
- [CHU 88] CHURCHLAND, P. **Matter and Consciousness**. Cambridge, Massachusetts:The MIT Press, 1988.
- [COH 01] COHEN, J. Computers and biology. **Communications of the ACM**, [S.l.], v.44, n.3, p.76–77, March, 2001.
- [COS 93] COSTA, A. C. R. **Inteligência de Máquina: Esboço de Uma Abordagem Construtivista**. P. Alegre, RS:Instituto de Informática - UFRGS, outubro, 1993. Tese de Doutorado.
- [CRA 96] CRAWFORD, E. T. **Arrhenius : From Ionic Theory to the Greenhouse Effect**. Watson Publishing International, 1996.
- [CRI 81] CRICK, F. **Life Itself**. Simon and Schuster, 1981.
- [DAR 59] DARWIN, C. R. **On The Origin of Species by Means of Natural Selection, or The Preservation of Favoured Races in the Struggle for Life**. Connecticut:Grolier Enterprises Corp. Danbury, 1859.
- [DAW 76] DAWKINS, R. **The Selfish Gene**. Oxford, UK:Oxford University Press, 1976.
- [DAW 00] DAWKINS, R. **Desvendando o Arco-Íris**. São Paulo:Companhia das Letras, 2000.
- [DEN 91] DENNETT, D. **Consciousness Explained**. Boston:Little, Brown, 1991.
- [DIA 98] DIAS, J. S. **Sensibilidade Paramétrica como Guia para o Treinamento Híbrido de Redes Neurais**. Florianópolis, SC:PGEEL - Universidade Federal de Santa Catarina, 1998. Tese de Doutorado.
- [DIN 00] DINIZ, J. A. F. **Métodos Filogenéticos Comparativos**. Ribeirão Preto:Holos Editora, 2000.
- [DOR 97] DORIGO, M. Ant colony system: A cooperative learning approach to the travelling salesman problem. **IEEE Trans. Evol. Comp**, [S.l.], v.1, p.53–66, 1997.
- [DRE 92] DREYFUS, H. L. **What Computers Still Can't Do**. Cambridge:MIT Press, 1992.
- [DUB 60] DUBOS, R. **Louis Pasteur: Free Lance of Science**. Da Capo Press, Inc., 1960.
- [EBE 90] EBERHART, R. C. **Neural Networks P C Tools: A Practical Guide**. Laurel, Maryland:Academic Press, Inc., 1990.
- [EDI 00] EDITORIAL. A evolução tem lógica? **Despertaí!**, [S.l.], v.81, n.11, p.31, jun, 2000.

- [FAL 00] FALQUETO, J.; BARRETO, J. M. Amplification of perspectives in the use of evolutionary computation. **IEEE International Symposium on Bio-Informatics and Biomedical Engineering**, Arlington, VA, USA, v.1, p.150–157, november, 2000.
- [FAL 01a] FALQUETO, J. et al. The measurement of artificial intelligence: An IQ for machines? **Proceedings of the IASTED: International Conference on Modelling, Simulation and Control**, Innsbruck, Austria, v.1, p.409–413, February, 2001.
- [FAL 01b] FALQUETO, J. et al. O desenvolvimento de uma métrica para sistemas de IA - considerações. **II Congreso Latinoamericano de Ingeniería Biomédica - www.hab2001.sld.cu**, [S.l.], v.2, 23-25 maio, 2001.
- [FOD 83] FODOR, J. A. **The Modularity of Mind**. Cambridge:MIT Press, 1983.
- [FOG 62] FOGEL, L. J. Autonomous data. **Industrial Res.**, [S.l.], v.4, p.14–19, 1962.
- [FOG 63] FOGEL, L. J. **Biotechnology: Concepts and Applications**. Englewood Cliffs, NJ:Prentice-Hall, 1963.
- [FOG 64] FOGEL, L. J. **On the Organization of Intellect**. University of California at Los Angeles, 1964. Tese de Doutorado.
- [FOG 66] FOGEL, L. J.; OWENS, A. J. **Artificial Intelligence Through Simulated Evolution**. John Wiley, 1966.
- [FOG 92] FOGEL, D. B. An analysis of evolutionary programming. In: Fogel, D. B., editors, **PROCEEDINGS OF THE FIRST ANNUAL CONFERENCE ON EVOLUTIONARY PROGRAMMING**, 1992. **Proceedings...** La Jolla, CA:[s.n.], 1992. p.43–51.
- [FOU 01] FOURNIER, J. Y. L'Intelligence à l'école. **Sciences Humaines**, [S.l.], v.1, n.116, p.34–37, mai, 2001.
- [FRA 00] FRANCESCHI, A. S. M. D.; ROISENBERG, M. Employing intelligent techniques to develop autonomous agents for network management. In: **SOCIETY FOR COMPUTER SIMULATION**, 2000. **Proceedings...** Passau:[s.n.], 2000. v.1.
- [FRE 91] FREEMAN, J. A. **Neural Networks - Algorithms, Applications and Programming Techniques**. Reading, MA:Addison-Wesley, 1991.
- [GAA 95] GAARDER, J. **O Mundo de Sofia: Romance da História da Filosofia**. São Paulo:Companhia Das Letras, 1995.
- [GAR 94] GARDNER, H. **Estruturas da Mente: A Teoria das Inteligências Múltiplas**. Porto Alegre:Artes Médicas, 1994.
- [GLE 00] GLENN, J. **Ciência da Computação - Uma Visão Abrangente**. Porto Alegre:Bookman, 2000.

- [GLO 89] GLOVER, F. Tabu search, part i. **Operations Research of America - Journal on Computing**, [S.I.], v.1, p.190–206, 1989.
- [GLO 97] GLOVER, F. **Tabu Search**. Norwell, MA:Kluwer Academic Publishers, 1997.
- [GOL 85] GOLDBERG, D. Alleles, loci and the traveling salesman problem. In: Grefenstette, J., editor, **PROCEEDINGS OF AN INTERNATIONAL CONFERENCE ON GENETIC ALGORITHMS AND THEIR APPLICATIONS**, 1985. **Proceedings...** Pittsburgh, PA:Lawrence Erlbaum, Hillsdale, New Jersey, 1985. p.154–159.
- [GOL 89] GOLDBERG, D. D. **Genetic Algorithms in Search, Optimization & Machine Learning**. NY:Addison-Wesley, 1989.
- [GOL 92] GOLDBERG, D. E.; HORN, J. What makes a problem hard for a classfier system. <ftp://rtfm.mit.edu:/pub/usenet/news.answers/ai-faq/genetic/part2>, [S.I.], v.1, p.1 – 15.3, 1992.
- [GOL 95] GOLEMAN, D. P. **Emotional Intlligence - Why It Can Matter More Than IQ for Character, Health and Lifelong Achievement**. USA:Bantam Books, 1995.
- [GOO 92] GOODWIN, B. **Thinking About Biology**, chapter Development as a robust natural process. Addison Wesley, 1992.
- [GRA 76] GRANGER, G. G. **La Théorie Aristotélicienne de la Science**. Paris:Aubier-Montagne, 1976.
- [GRE 86] GREFENSTETTE, J. J. Optimization of control parameters for genetic algorithm. **IEEE Transactions on Systems, Man, and Cybernetics**, [S.I.], v.16, n.1, p.122–128, 1986.
- [GRE 91] GREFENSTETTE, J. J. **Conditions for Implicit Parallelism**. Morgan Kaufmann, 1991.
- [GRU 92] GRUAU, F. Genetic synthesis of boolean neural networks with a cell rewriting developmental process. In: Whitley, L. D., editors, [S.N.], 1992. **Proceedings...** [S.I.]:COGANN-92: International Workshop aon Combinations of Genetic Algorithms and Neural Networks, 1992.
- [GUI 71] GUILFORD, J. P. **The Analysis of Intelligence**. New York:McGraw-Hill, 1971.
- [GUR 97] GURNEY, K. **An Introduction to Neural Networks**. London, UK:UCL Press, 1997.
- [HAD 73] HADLEY, G. **Linear Algebra**. Reading, Massachusetts:Addison-Wesley Pub. Co., 1973.
- [HAL 47] HALDANE, J. B. S. **What Is Life?** New York:Boni and Gaer, 1947.
- [HAR 95] HART, W. E. **Optimization with Genetic Algorithms Hybrids That Use Local Search**, chapter1, p.1. Addison-Wesley, 1995.

- [HEB 49] HEBB, D. O. **The Organization of Behavior**. New York:Wiley, 1949.
- [HIL 85] HILLIS, D. W. **The Connection Machine**. Cambridge:MIT Press, 1985.
- [HOF 86] HOFSTADTER, D. R. **The Mind's I: Fantasies and Reflections on Self and Soul**. New York:Penguin Books, 1986.
- [HOL 62] HOLLAND, J. H. Outline for logical theory of adaptive systems. **Journal of the ACM**, [S.l.], v.3, p.297–314, 1962.
- [HOL 75] HOLLAND, J. H. **Adaptation in Natural and Artificial Systems**. Ann Arbor:The University of Michigan Press, 1975.
- [HOL 78] HOLLAND, J. H. **Cognitive Systems Based on Adaptive Algorithm**, chapter 1, p.1. Academic Press, NY, 1978.
- [HOL 90] HOLLOBLER, B. **The Ants**. Cambridge, MA:Harvard University Press, 1990.
- [HUB 79] HUBEL, D. H. **The Brain**, v.1, chapter 6 The chemistry of the brain, p.2–14. Freeman, Scientific American, San Francisco, 1979.
- [HUI 64] HUISMAN, D. **Curso Moderno de Filosofia**. Rio de Janeiro:Freitas Bastos, 3. ed., 1964.
- [HUT 99] HUTEAU, M. **Évaluer L'Intelligence: Psychométrie Cognitive**. Paris:Presses Universitaires, 1999.
- [JEN 00] JENSEN, C. **QwikNet**. [S.n.], Redmond, WA, cjensen@kagi.com, 2000. www.kagi.com. Acesso em 11 dez. 2001.
- [JOH 98] JOHNSON, R. A. **Applied Multivariate Statistical Analysis**. New Jersey:Prentice Hall, 1998.
- [JON 75] JONG, K. D. **An Analysis of the Behavior of a Class of Genetic Adaptive Systems**. University of Michigan, 1975. Tese de Doutorado.
- [JON 93] JONG, K. A. D. **Genetic Algorithms are NOT Function Optimizers**. Morgan Kaufmann, 1993.
- [KIR 83] KIRKPATRICK, S.; JR, C. D. G. Optimization by simulated annealing. **Science**, [S.l.], v.220, p.671–680, 1983.
- [KIT 90] KITANO, H. Designing neural networks using genetic algorithms with graph generation system. **Complex Systems**, [S.l.], v.4, p.461–476, 1990.
- [KOM 00] KOMOSINSKI, L. J.; LACERDA, C. D. F. Uso de agentes para apoio à mediação de diálogos entre estudantes via internet. **V Congresso Iberoamericano de Informatica Educativa** (www.c5.cl/ieinvestiga/actas/ribie2000/), Viña del Mar (Chile), v.1, p.Public. eletrônica, dez., 2000.
- [KOZ 92] KOZA, J. R. **Genetic Programming: On the Programming of Computers by Means of Natural Selection**. Cambridge:MIT Press, 1992.

- [KUH 62] KUHN, T. S. **The Structure of Scientific Revolutions**. Chicago:Chicago University Press, 1962.
- [LAF 80] LAFARGUE, P. **The Right to Be Lazy**. Ardmore, PA:Fifth Season Press, 1999 (Trad. 1880).
- [LAN 95] LANGLEY, P. Applications of machine learning and rule induction. **Communications of the ACM**, [S.l.], v.38, n.11, p.55–64, November, 1995.
- [LAP 69] LAPLACE, P. S. **Celestial Mechanics**, v.5. Washington, DC:Chelsea Pub, 1969.
- [LAP 00] LAPRESTÉ, J. T. **Introduction à MATLAB**. Paris:ELLIPSES - Edition Marketing, 2000. www.mathworks.com/products/neuralnet. Acesso em 15 dez. 2001.
- [LAU 01] LAUTREY, J. Intelligence, de la mesure aux modèles. **Sciences Humaines**, [S.l.], v.1, n.116, p.22–27, mai, 2001.
- [LEH 00] LEHRER, C. Operador de seleção para algoritmos genéticos baseado no jogo hawk-dove. Florianópolis, SC:PGCC - Universidade Federal de Santa Catarina, Outubro, 2000. Dissertação de Mestrado.
- [LES 90] LESSER, V. R. An overview of DAI: Viewing distributed AI as distributed search. In **Journal of Japanese Society for Artificial Intelligence-Special Issue on Distributed Artificial Intelligence**, [S.l.], v.5, p.392–400, 1990, R. Nakano and S. Doshita (eds.), 1990.
- [LEW 84] LEWIN, R. **A Vida no Limite do Caos**. Rio de Janeiro:Ed. Rocco, 1984.
- [LOP 98] LOPES, S. G. B. C. **Bio - Introdução ao Estudo dos Seres Vivos**, v.2. São Paulo:Ed. Saraiva, 1998.
- [LUG 92] LUGER, G. F. **Artificial Intelligence: Structures and Strategies for Complex Problem Solving**. Redwood City, Calif.:Benjamin/Cummings Pub. Co. Inc., 2. ed., 1992. 4p.
- [MAR 91] MARSHALL, I. N. **Quantum Self: Human Nature and Consciousness Defined by the New Physics**. Morrow,William & Co., 1991.
- [MAR 96] MARSHALL, E. L. **The Human Genome Project : Cracking the Code Within Us**. Franklin Watts, Incorporated, 1996.
- [MAS 93] MASON, A. J. Crossover non-linearity ratios and the genetic alorithm: Escaping the blinkers of schema processing and intrinsic parallelism. Auckland - N. Zealand:School of Engineering - University of Auckland, 1993. Relatório Técnico 535b.
- [MAS 99] MASICLAT, P. D. **The Catholic Encyclopedia**, v.3. www.newadvent.org/cathen/03016a:New Advent Org., 1999. Acesso em 11 fev. 2001.

- [MAZ 99] MAZZUCCO, J. **Uma Abordagem Híbrida do Problema de Programação da Produção Através dos Algoritmos Simulated Annealing e Genético**. Florianópolis, SC:Universidade Federal de Santa Catarina - PPGEPP, 1999. Tese de Doutorado.
- [MCC 43] MCCULLOCH, W. S. A logical calculus of ideas immanent in nervous activity. **Bull. of Mathematical biophysics**, [S.l.], v.5, p.115–133, 1943.
- [MIC 92] MICHALEWICZ, Z. **Genetics Algorithms + Data Structures = Evolution Programs**. Springer-Verlag, 1992.
- [MIL 89] MILLER, G. F.; TODD, P. M. Designing neural networks using genetic algorithms. In: Schaffer, J. D., editor, **PROCEEDINGS OF THE THIRD INTERNATIONAL CONFERENCE ON GENETIC ALGORITHMS**, 1989. **Proceedings...** [S.l.]:Morgan Kaufmann, 1989.
- [MIN 67] MINSKY, M. **Computation: Finite and Infinite Machines**. Englewood Cliffs:Prentice-Hall, 1967.
- [MIN 85] MINSKY, M. **The Society of Mind**. New York:Simon and Schuster, 1985.
- [MIN 88a] MINSKY, M. **Perceptrons, Expanded Edition**. Cambridge:MIT Press, 1988.
- [MIN 88b] MINSKY, M. L. **Perceptrons: An Introduction to Computacional Geometry**. Cambridge:MIT Press, 1988. 3 rd impression (modified).
- [MIN 91] MINSKY, M. Logical versus analogical or symbolic versus connectionist or neat versus scruffy. **AI Magazine**, [S.l.], v.1, p.34–51, Summer, 1991.
- [MIT 96] MITCHELL, M. **An Introduction to Genetic Algorithms**. Cambridge, MA:The MIT Press, 1996.
- [MIT 00] MITCHELL, M. Can evolution explain how the mind works? a review of the evolutionary psychology debates. www.santafe.edu/mm/paper-abstracts.html#ep-essay, [S.l.], v.1, p.1–15, 2000.
- [MON 71] MONTEIRO, L. H. J. **Iniciação às Estruturas Algébricas**. S. Paulo:Liv. Nobel, 1971.
- [MON 89] MONTANA, D. J. Training feedforward networks using genetic algorithms. In: **PROCEEDINGS OF THE INTERNATIONAL JOINT CONFERENCE ON ARTIFICIAL INTELLIGENCE**, 1989. **Proceedings...** [S.l.]:Morgan Kaufmann, 1989.
- [MOR 84] MOREAU, R. **Ainsi Naquit L'informatique**. Paris:Dunod, 1984.
- [MUR 94] MURRAY, C. **The Bell Curve: Intelligence and Class Structure in American Life**. New York:The Free Press, 1994.
- [NAI 83] NAISSE, J. P. Science et mithe devant l'avenir. **Laïcité - Évolution**, [S.l.], v.2, p.127–150, 1983.

- [NEW 63] NEWELL, A.; SHAW, J. C. **Computers and Thought**, chapter Empirical exploration with the logic theory machine: a case study in heuristics. McGraw-Hill, New York, 1963.
- [NEW 82] NEWELL, A. Physical symbol systems. **Cognitive Science**, [S.l.], v.18, p.87–127, 1982.
- [NIC 83] NICOLIS, G. Thermodynamique de l'évolution. **Laïcité - Évolution**, [S.l.], v.2, p.91–126, 1983.
- [NIC 98] NICOLIS, G. **Exploring Complexity - an Introduction**. New York:W. H. Freeman and Co., 1998.
- [OPA 55] OPARIN, A. I. **A Origem da Vida**. Rio de Janeiro:Editorial Vitória, 1955.
- [O'R 94] O'REILLY, U. M. Program search with hierarchical variable length representation: Genetic programming, simulated annealing, and hill climbing. In: Davidor, Y.; Schwefel, H. P., editors, **PARALLEL PROBLEM SOLVING FROM NATURE - PPSN III**, 1994. **Proceedings...** Berlin:Springer-Verlag (Lectures in Computer Science), 1994. v.866.
- [OST 78] OSTER, G. F. **Cast and Ecology in the Social Insects**. Princeton:Princeton University Press, 1978.
- [PAT 97] PATTERSON, D. A. **Computer Organization & Design: The Hardware/Software Interface**. San Francisco:Morgan Kaufmann Pub, 2. ed., 1997.
- [PEC 93] PECK, C. C. A review and critique of genetic algorithm theories. Cincinnati:Department of Electrical and Computer Engineering - University of Cincinnati, 1993. Relatório Técnico 153/6/93.
- [PEN 94] PENROSE, R. **The Shadows of the Mind**. London:Oxford University Press, 1994.
- [PIC 83] PICCIOTTO, E. La géologie au siècle de Darwin: Une esquisse de ses rapports avec la théorie de l'évolution biologique. **Laïcité - Évolution**, [S.l.], v.2, p.23–45, 1983.
- [PIN 97] PINKER, S. **How the Mind Works**. New York:W W Norton, 1997.
- [POP 77] POPPER, K. R. **The Self and its Brain**. Berlin:Springer-Verlag, 1977.
- [POS 43] POST, E. Formal reductions of the general combinatorial problem. **American journal of Mathematics**, [S.l.], v.65, p.197–268, 1943.
- [PRI 85] PRIGOGINE, I. Physique, temps et complexité. **Afronter la complexité**, Bruxelles, v.Laïcité, 3, p.135–163, 1985.
- [PRI 90] PRIBRAM, K. **Brain and Perception**. Lawrence Erlbaum Associates, Inc., 1990.
- [PRI 96] PRIGOGINE, I. **O Fim das Certezas - Tempo, Caos e as Leis da Natureza**. São Paulo:Edit. Fundação UNESP, 1996.

- [RAN 75] RANDELL, B. **The Origins of Digital Computers: Selected Papers.** berlin:Springer-Verlag, 1975.
- [RAS 83] RASMONT, R. La théorie de l'évolution cent ans après Darwin: Des lumières e des ombres. **Laïcité - Évolution**, [S.l.], v.2, p.47–89, 1983.
- [REC 65] RECHENBERG, I. Cybernetic solution path of en experimental problem. **Roy. Aircr. Establ., libr. transl.**, Farnborough, UK, v.1, p.1122, 1965.
- [REC 73] RECHENBERG, I. **Evolutionsstrategie: Optimierung Technischer Systeme Nach Prinzipien der Biologischen Evolution.** Stuttgart:Frommann-Holzboog, 1973.
- [RIO 88] RIOLO, R. L. **Empirical Studies of Default Hierarchies and Sequences of Rules in Learning Classifier Systems.** Univ. of Michigan, 1988. Tese de Doutorado.
- [ROB 01] ROBERT, A. et al. A Bose-Einstein condensate of metastable atoms. **Science**, [S.l.], v.292, p.461–462, April, 2001.
- [ROI 97] ROISENBERG, M.; BARRETO, J. M. Feedforward and recurrent neural networks complexity power: A comparison based on a concrete example. **Anais do III Congresso Brasileiro de Redes Neurais**, [S.l.], v.1, p.1–6, 1997.
- [ROI 98] ROISENBERG, M. **Emergência da Inteligência em Agentes Autônomos Através de Modelos Inspirados na Natureza.** Florianópolis, SC:PGEEL - Universidade Federal de Santa Catarina, 1998. Tese de Doutorado.
- [ROS 58] ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological review**, [S.l.], v.65, p.386–408, 1958.
- [ROS 99] ROSSBACH, S. **Feng Shui.** Rio de Janeiro:Ediouro, 1999.
- [RUD 92] RUDOLPH, G. Parallel approaches to stochastic global optimization. In: Joosen, W., editors, **PARALLEL COMPUTING: FROM THEORY TO SOUND PRACTICE**, 1992. **Proceedings...** Amsterdam:European workshop on parallel computing, 1992. p.256–267.
- [RUI 65] RUIZ, L. A. F. **Curso de Termodinámica con 310 Problemas.** Buenos Aires:Ediciones Litenia, 1965.
- [RUM 86a] RUMELHART, D. E.; HINTON, G. E. **Learning Internal Representations by Error Propagation**, v.Volume 1: Foundations, chapter Parallel Distributed Processing. MIT Press, 1986.
- [RUM 86b] RUMELHART, D. E.; MCCLELLAND, J. L. **Parallel Distributed Processing**, v.2, chapter Psychological and biological models. MIT Press, 1986.
- [SAI 88] SAITO, K. Medical diagnostic expert system based on PDP model. In: **PROC. IEEE INT'L CONF. NEURAL NETWORKS**, 1988. **Proceedings...** [S.l.]:[s.n.], 1988. p.255–262.

- [SCH 65] SCHWEFEL, H. P. **Kybernetische Evolution Als Strategie der Experimentellen Forschung in der Strömungstechnik**. Berlin:Technical University of Berlin, 1965. Tese de Doutorado.
- [SCH 87] SCHWEFEL, H. P. Collective phenomena in evolutionary research. **31 st Annual Meeting of the International Society for General System Research**, Budapest, v.2, p.1025–1033, 1987.
- [SCH 94] SCHWAB, G. **As Mais Belas Histórias da Antiguidade Clássica**, v.1. São Paulo:Paz e Terra, 1994. 18p.
- [SEA 84] SEARLE, J. **Mente, Cérebro e Ciência**. Lisboa:70 Ltda., 1984.
- [SHA 48] SHANNON, C. E. A mathematical theory of communication. **The Bell System Technical Journal**, [S.l.], v.V 27, p.379–423 and 623–656, 1948.
- [SHA 84] SHANK, R. **The Cognitive Computer: On Language, Learning and Artificial Intelligence**. Massachusetts:Addison Wesley, 1984.
- [SIM 58] SIMON, H. A. Heuristic problem solving: The next advance in operations research. **Operations Research**, [S.l.], v.6, p.6, jan-feb, 1958.
- [SIM 81] SIMON, H. A. **The Sciences of Artificial**. Cambridge:MIT Press, 1981.
- [STA 93] STAPP, H. **Mind, Matter and Quantum Mechanics**. Berlin:Springer-Verlag, 1993.
- [STE 84] STENGERS, I. **Order Out of Chaos**. Bantam Doubleday Dell Publishing Group, 1984.
- [STE 95] STEMMER, M. R. Implementation and test of an integrated environment for adaptive neural control. **II Latin American Seminar on Advanced Control (LASAC'95) and IV Seminar on System Identification, Parameter Estimation and Adaptive Control (SISEPCA'95)**, [S.l.], v.1, September 27-29, 1995.
- [STE 97] STERNBERG, R. J. **Cognitive Psychology**. Holt Rinehart & Winston, 1997.
- [STR 00] STRASSMANN, J. Chimeras and cheater clones in dictyostelium discoideum. www.dictybase.org/dicty2000.pdf, [S.l.], v.1, 30 jul - 4 ago 2000.
- [TAH 86] TAHAN, M. Maravilhas da matemática. **Apicultura no Brasil**, [S.l.], v.14, p.35–37, maio/junho1986.
- [TAN 95] TANOMARU, J. Motivação, fundamentos e aplicações de algoritmos genéticos. In: **III CONGRESSO BRASILEIRO DE REDES NEURAIIS E III ESCOLA DE REDES NEURAIIS**, 1995. **Proceedings...** Curitiba:[s.n.], 1995.
- [TOF 00] TOFFLER, A. 'terceira onda' é uma realidade irreversível. **O Estado de São Paulo - Caderno Economia**, [S.l.], v.1, p.B–10, 09.07.2000.
- [TOU 90] Touretzky, D. S. et al., editors. **The Evolution of Learning: An Experiment in Genetic Connectionism**. Morgan Kaufmann, 1990.

- [TUR 50] TURING, A. Computing machinery and intelligence. **Mind**, [S.l.], v.59, n.236, p.433–460, 1950.
- [TVE 98] TVETER, D. R. **The Pattern Recognition Basis of Artificial Intelligence**. Los Alamitos - California:IEEE Computer Society Press, 1998.
- [UZU 97] UZUNIAN, A. **Biologia**. São Paulo:Ed. Harbra, 1997.
- [VEN 01] VENTER, J. C. The sequence of the human genome. **Science**, [S.l.], v.291, p.1304–1351, feb, 2001.
- [VEY 89] VEYNE, P. **História Da Vida Privada**, v.I, chapterO império romano, p.123–139. Companhia das Letras, S. Paulo, 1989.
- [VYG 87] VYGOTSKY, L. S. **A Formação Social da Mente**. São Paulo:Martins Fontes, 1987.
- [WAD 62] WADDINGTON, C. H. **The Nature of Life; The Main Problems and Trends of Thought in Modern Biology**. New York:B & Noble, 1962.
- [WAL 00] WALKERS, E. H. **The Physics of Consciousness: Quantum Mind and the Meaning of Life**. Ed. Perseus Books, 2000.
- [WHI 92] WHITLEY, L. D. COGANN-92: International workshop on combinations of genetic algortihms and neural networks. In: [S.N.], 1992. **Proceedings...** [S.l.]:IEEE Computer Society Press, 1992.
- [WID 60] WIDROW, B. Adaptive switching circuits. **IRE WESCON Convention Record**, New York, v.1, p.96–104, 1960.
- [WIE 82] WIESE, H. **Nova Apicultura**. Porto Alegre:Liv. Edit. Agropecuária, 1982.
- [WIN 73] WINOGRAD, T. **Computer Models of Thought and Language**, chapter A procedural model of language understanding. W H Freeman Press, San Francisco, 1973.
- [ZEI 87] ZEIGLER, B. P. Knowledge representation from neston to minsky and beyond. **Applied Artificial Intelligence**, [S.l.], v.1, n.1, p.87–107, 1987.
- [ZOH 00] ZOHAR, D. **S.Q: Connecting with our Spiritual Intelligence**. USA:Bloomsbury Pub Plc, 2000.